

## بررسی تجربی گرایش توزیع دوجمله‌ای به پواسن

رضا مؤمنی<sup>۱</sup>

یدالله واقعی<sup>۲</sup>

### چکیده

توزیع‌های دوجمله‌ای و پواسن از جمله توزیع‌هایی هستند که در آمار و احتمال کاربردهای فراوانی دارند. اگرچه این دو توزیع تعاریف و فرمولهای مختلفی دارند ولی تحت شرایط خاصی به هم نزدیک می‌شوند. به سادگی می‌توان نشان داد چنانچه در توزیع دوجمله‌ای حجم نمونه ( $n$ ) به بینهایت و احتمال موفقیت ( $p$ ) به صفر میل کند و  $np$  مقدار ثابتی باقی بماند، توزیع دوجمله‌ای به توزیع پواسن میل می‌کند و در این صورت است که می‌توان بجای توزیع دوجمله‌ای از توزیع پواسن استفاده کرد.

با توجه به اینکه در عمل غیرممکن است حجم نمونه به بینهایت و احتمال موفقیت به صفر برسد در این مقاله به دنبال شرایط عملی هستیم که با اندکی خطأ(تقریب) بتوان بجای توزیع دوجمله‌ای از توزیع پواسن استفاده نمود. برای این منظور اختلاف دو توزیع به ازای مقادیر مختلف  $X$  در قالب ملاکی که «جدز میانگین مریع اختلافات» نامیده شده برای دامنه گسترده‌ای از  $n$  و  $p$  که به ازای آنها تقریب دوجمله‌ای به پواسن مناسب است، مشخص شده‌اند.

واژه‌های کلیدی: پواسن، دوجمله‌ای، قضایای حدی.

### ۱. مقدمه

طبق یک تعریف ساده، اگر یک آزمایش برنولی در شرایط یکسان به طور مستقل از هم  $n$  بار تکرار شود در این صورت متغیر تصادفی  $X$ : تعداد پیروزیها در این  $n$  آزمایش، دارای توزیع دوجمله‌ای است. همچنین اگر از جامعه‌ای که شامل دو گروه (مثلًاً دارای بیماری سرماخوردگی و فاقد بیماری سرماخوردگی) باشد، یک نمونه تصادفی  $n$  تایی به روش با جایگذاری گرفته شود، در این صورت تعداد افراد در هر یک از دو گروه یک متغیر تصادفی با توزیع دوجمله‌ای خواهد بود.

گرایش توزیع‌های احتمال به یکدیگر یکی از مباحث جالب در بحث نظریه احتمال است و از طرفی کار محاسبات و استنباط آماری را ساده یا ممکن می‌سازد. توزیع‌های دوجمله‌ای و پواسن دو توزیع پایه و بسیار مهم آمار هستند که معمولاً به دانشجویان همه رشته‌هایی که درس آمار و احتمال دارند آموخته می‌شوند. گرایش توزیع دوجمله‌ای به پواسن یکی از مباحث نظری و در عین حال دارای کاربرد در آمار و احتمال می‌باشد که سبب سادگی محاسبات می‌شود.

<sup>۱</sup> کارشناس آمار

<sup>۲</sup> گروه آمار، دانشگاه بیرجند

به عنوان یک ملاک، جذر میانگین مربع اختلافات<sup>۳</sup> دو توزیع را به صورت زیر تعریف می‌کیم.

$$rmsd = \sqrt{\frac{1}{n+1} \sum_{x=0}^n (f_2(x) - f_1(x))^2}$$

این ملاک به نوعی میانگین اختلافات دو توزیع به ازای مقادیر مختلف  $n$  را نشان می‌دهد. هر چه اختلاف دو توزیع بیشتر باشد مقدار عددی این ملاک بزرگتر خواهد بود (و برعکس). بررسی‌های مقدماتی مشخص کرد که چنانچه  $msd < 0.005$  باشد می‌توان از توزیع پواسن به عنوان تقریب توزیع دوجمله‌ای استفاده نمود، زیرا در این صورت اختلاف احتمالات دو توزیع در نقاط مختلف به طور متوسط از ۰/۰۱ کمتر خواهد بود (مؤمنی، ۱۳۸۲). در این مقاله می‌خواهیم با استفاده از ملاک فوق بینیم به ازای چه  $n$  و  $p$  هایی اختلاف دو توزیع ناچیز است، یعنی  $p, n$  چه مقادیری باشند که بتوان توزیع پواسن را به عنوان تقریبی از توزیع دوجمله‌ای مورد استفاده قرار داد.

## ۲. بررسی اختلاف دو توزیع به ازای $p, n$ های مختلف

به منظور یافتن مقادیری از  $p, n$  که تقریب مناسبی را برای استفاده از توزیع پواسن بجای توزیع دوجمله‌ای فراهم می‌کنند، نخست برای مقادیر مختلف  $n$  و  $p$ :

(۵)  $p = 0.05, 0.1, 0.15, \dots, 0.5 ; n = 5, 10, 15, \dots, 100$   
 احتمالات توزیع دوجمله‌ای و پواسن با  $np = \lambda$  محاسبه شد. سپس برای هر  $n$  و  $p$  مقدار  $rmsd$  که نشان‌دهنده میزان اختلاف دو توزیع است به دست آمد. جدول ۱ مقادیر  $rmsd$  را که با استفاده از یک برنامه SPLUS محاسبه شده است. به ازای مقادیر مختلف  $n$  و  $p$  نشان می‌دهد (مؤمنی، ۱۳۸۲).

در این جدول خطوط پله مانندی رسم شده است که مقادیر بالای پله‌ها از ۰/۰۰۵ بیشتر و زیر آنها از ۰/۰۰۵ کمتر است. مقادیری که زیر پله‌ها هستند، مقادیری از  $p, n$  را مشخص می‌کنند که تقریب توزیع پواسن برای توزیع دوجمله‌ای مناسب است یعنی به ازای این  $n$  و  $p$  ها می‌توان از توزیع پواسن بجای توزیع دوجمله‌ای استفاده نمود. به عنوان

تعداد رخدادها یا موقیتها در یک فاصله زمانی یا ناحیه مکانی را گاهی می‌توان با توزیع پواسن مدل‌سازی کرد. یکی از فرضهای پایه‌ای که توزیع پواسن بر مبنای آن ساخته می‌شود این است که در فواصل زمانی (مکانی) کوچک احتمال یک رخداد متناسب با طول فاصله باشد. همچنین تعداد رخدادها در فواصل زمانی (مکانی) مجزا باید از هم مستقل باشند. به عنوان مثال «تعداد غلطهای چاپی در یک صفحه از کتاب»، «تعداد مشتریان اداره پست در یک روز معین» و «تعداد یک نوع میکروب در یک سانتی‌متر مکعب خون» مصاديقی از توزیع پواسن هستند. وقتی در توزیع دوجمله‌ای  $P(n, p)$  باشد محاسبه احتمالهای دوجمله‌ای به دلیل وجود ضربی  $(x+n)! / (x! n!)$  در تابع احتمال مشکل می‌باشد. در این صورت تحت شرایط مشخصی می‌توان بجای توزیع دوجمله‌ای از توزیع پواسن استفاده نمود. طبق یک قضیه مشهور در آمار ریاضی چنانچه در توزیع دوجمله‌ای به پواسن میل  $np = ۰$  ثابت نیست، توزیع دوجمله‌ای به پواسن میل می‌کند. این قضیه را مستقیماً با چند گرفتن از تابع احتمال دوجمله‌ای می‌توان اثبات کرد (مثلاً، عمیدی، ۱۳۸۰، ص ۲۰۱). از روش تابع مولد گشاور نیز می‌توان گرایش توزیع دوجمله‌ای به پواسن را نشان داد. اما در عمل بعید است که  $n$  به بینهایت و  $p$  به صفر برسد. لذا یافتن شرایط عملی که تحت این شرایط توزیع پواسن تقریب نسبتاً خوبی برای توزیع دوجمله‌ای باشد از اهمیت خاصی برخوردار است. بعضی آمارشناسان گفتند که وقتی  $n \geq ۲۰$  و  $p \leq 0.05$  باشد توزیع پواسن تقریب خوبی برای احتمالهای دوجمله‌ای است و وقتی  $n \geq ۱۰۰$  و  $np < ۱.۰$  تقریب عالی است (مثلاً، عمیدی، ۱۳۸۰). در این مقاله می‌خواهیم موضوع را موشکافی کرده و با مقایسه احتمالات توزیع‌های دوجمله‌ای و پواسن، مقادیر مناسب  $p$  و  $n$  را که به ازای آنها تقریب مناسب است، پیدا کیم.

فرض کنید  $f_1(x)$  و  $f_2(x)$  به ترتیب نشان‌دهنده احتمالات توزیع‌های دوجمله‌ای با پارامترهای  $n$  و  $p$  و پواسن با پارامتر  $\lambda = np$  باشد، یعنی

$$f_1(x) = \binom{n}{x} p^x (1-p)^{n-x}, \quad x = 0, 1, 2, 3, \dots, n$$

$$f_2(x) = \frac{e^{-\lambda} \lambda^x}{x!}, \quad x = 0, 1, 2, 3, \dots, n, n+1, \dots$$

### ۳. بررسی نمودار تراز اختلافات دو توزیع

جدول ۱ مقادیر rmsd را در یک شبکه شطرنجی (ماتریسی) نشان می‌دهند. هر مقدار داخل این جدول بیانگر میزان اختلاف دو توزیع دو جمله‌ای و پواسن به ازای  $n = p$  می‌متناظر با سطر و ستون مقدار موردنظر است. با توجه به اینکه اغلب تفسیر نمودارها و شکل‌ها ساده‌تر از جداول عددی است، در شکل ۲ نمودار تراز<sup>۴</sup> مقادیر rmsd با PLUS رسم شده است. در این نمودار محورهای افقی و عمودی مشخص کننده مقادیر  $n$  و  $p$  (متناظر با جدول ۱) هستند و منحنی‌های مشخص شده روی آن، که اصطلاحاً منحنی تراز نامیده می‌شود، مشخص کننده نقاطی از  $n$  و  $p$  هستند که دارای rmsd (جزء میانگین مربع اختلافات) یکسان می‌باشند و این مقدار (rmsd) در حاشیه این منحنی‌ها چاپ شده است. به عنوان مثال منحنی که کنار آن  $0.002$  نوشته شده مشخص کننده مقادیر مختلف  $n$  و  $p$  است که جذر میانگین مربع اختلافات دو توزیع به ازای آنها  $0.002$  می‌باشد. روند این منحنی و سایر منحنی‌های تراز نشان می‌دهد که هر چه  $p$  افزایش می‌یابد به مقدار  $n$  بزرگتری برای رسیدن به یک rmsd ثابت (به عنوان مثال  $0.002$ ) نیاز داریم. مثلاً هنگامی که  $p$  برابر  $0.05$  باشد حدوداً  $n = 35$  باشد تا حدود  $0.002$  باشد ولی هنگامی که  $p$  برابر  $0.1$  باشد حدوداً  $n = 60$  باشد تا rmsd حدود  $0.002$  باشد.

منحنی تراز در شکل ۲ از پایین به بالا مقادیر افزایشی دارند، یعنی با افزایش  $p$  مقدار rmsd نیز طبق مقادیر مشخص شده در کنار منحنی‌ها افزایش می‌یابند. به کمک این منحنی‌ها در صورت نیاز می‌توان کیفیت تقریب رابر حسب مقادیر rmsd مندرج در حاشیه منحنی‌ها به سطوح خیلی خوب، مناسب، نامناسب رده‌بندی کرد. در اینجا با توجه به مباحث قبلی، صرفاً سطوح مناسب و نامناسب را مشخص می‌کنیم. با توجه به اینکه مقدار  $0.005$  در rmsd را به عنوان مرز مناسب بودن تقریب دو جمله‌ای به پواسن پذیرفت‌ایم، منحنی تراز  $0.005$  و نقاط زیر آن (که متناظر با منحنی‌های تراز کمتر از  $0.005$  هستند) مشخص کننده مقادیری از  $n$  و  $p$  هستند که تقریب به ازای آنها مناسب است. به عبارت دیگر زیر منحنی تراز  $0.005$  تقریب مناسب و بالای آن تقریب نامناسب می‌باشد. این منحنی مشخص می‌کند که به ازای  $0.04 > p$  برای هر کمتر از  $100$  تقریب نامناسب است.

مثال به ازای  $0.05 = p$  و  $n = 5$  مقدار rmsd برابر  $0.0044$  می‌باشد که نشان‌دهنده تقریب خوب توزیع پواسن برای دو جمله‌ای است! برای بررسی بیشتر این موضوع در شکل ۱ نمودار احتمالات توزیع دو جمله‌ای (باعلامت  $*$ ) و پواسن (با علامت  $*$ ) به ازای  $n = 5$  و  $p = 0.05$  و  $\lambda = 0.25$  نشان داده شده است.

با توجه به شکل ۱ مشاهده می‌شود که توابع احتمال توزیع دو جمله‌ای و پواسن به ازای  $n = 5$ ،  $p = 0.05$ ،  $\lambda = 0.25$  در نقاط  $5, 4, 3, 2, 1, 0$  تقریباً با هم برابرند و اختلاف چندانی ندارند. لذا برای  $n = 5$  هنگامیکه  $p = 0.05$  یا  $(p < 0.05)$  تقریب مناسب است.

بررسی سایر مقادیر rmsd زیر ستون  $0.05 = p$  جدول ۱ نشان می‌دهد که به ازای همه مقادیر  $100, 10, 15, \dots, 1$ ، مقدار rmsd کوچک است و علاوه بر این با افزایش  $n$  از  $5$  به سمت  $100$  مقدار rmsd از  $0.0044$  به  $0.0008$  کاهش می‌یابد، به عبارت دیگر با افزایش  $n$  اختلاف دو توزیع کم شده و تقریب مناسب‌تر می‌شود.

به طور خلاصه می‌توان چنین بیان کرد که هرگاه  $p = 0.05$  (یا  $p < 0.05$ ) باشد به ازای  $n \geq 5$  تقریب دو جمله‌ای به پواسن نسبتاً خوب است. جای بسی تعجب است هنگامی که  $p = 0.05$  (یا کمتر از آن) باشد حتی به ازای مقادیر کوچک  $n$  مثل  $5$  و  $10$  نیز تقریب مناسب است، زیرا بر طبق شرایط عملی که در اغلب کتابهای آمار و احتمال بیان شده می‌باشد،  $p \leq 0.05$  باشد، حال آنکه نتیجه بررسی ما نشان می‌دهد که شرط  $n \geq 20$  خیلی قوی است و  $n \geq 5$  کافی است.

اگر چه ثئوری بیان می‌کند که باید  $p$  به سمت صفر میل کند ولی برای  $p$ ‌های بزرگتر از  $0.05$  نیز مشاهده می‌شود که با افزایش  $n$  تقریب مناسب می‌شود، به عنوان مثال با  $p = 0.1$  برای  $n \geq 20$  و با  $p = 0.15$  برای  $n \geq 30$  تقریب مناسب است، حتی برای  $p = 0.4$  که بطور معنی‌داری از صفر دور است مشاهده می‌شود که برای  $n = 100$  تقریب مناسب است. لذا مرز یکنواختی را نمی‌توان بر حسب  $n$  و  $p$  برای نزدیکی دو توزیع مشخص کرد، زیرا نزدیکی دو توزیع بستگی به تغییرات توأم  $n$  و  $p$  دارد.

تقریب مناسب خواهد بود. اگر  $p$  بین  $0.15 \leq p < 0.20$  باشد می‌باشد  $n$  بزرگتر یا مساوی  $30$  و اگر  $p$  بین  $0.15 \leq p < 0.20$  باشد می‌باشد  $n$  بزرگتر یا مساوی  $40$  باشد، حتی اگر  $p$  بزرگتر از  $0.20$  (حداکثر تا  $0.40$ ) باشد، مقادیری از  $n$  وجود دارد که به ازای آنها تقریب توزیع دوجمله‌ای به پواسن مناسب است. بنابراین ملاحظه می‌شود که شرط  $p$  کمتر از  $0.10$  مناسب است. کتابهای آماری به عنوان شرط عملی برای گرایش دوجمله‌ای به پواسن ذکر شده، ضروری نیست و اگر  $p$  کمتر از  $0.05$  باشد شرط  $n \geq 20$  رامی توان محدودتر نمود. در شکل ۲ نموداری رسم شده که به ازای مقادیر مختلف  $n$  و  $p$  میزان اختلاف دو توزیع (با استفاده از ملاک  $\text{rmsd}$ ) و در نتیجه میزان مناسب بودن استفاده از توزیع پواسن بجای دوجمله‌ای را نشان می‌دهد و بطور مفصل مشخص می‌کند که به ازای چه مقادیری از  $n$  و  $p$  می‌توان از توزیع پواسن به عنوان تقریب دوجمله‌ای استفاده نمود و میزان دقت تقریب نیز با استفاده از منحنی‌های تراز مشخص می‌شود که مناسب است خواننده برای مشاهده جزئیات بیشتر به آن مراجعه نماید.

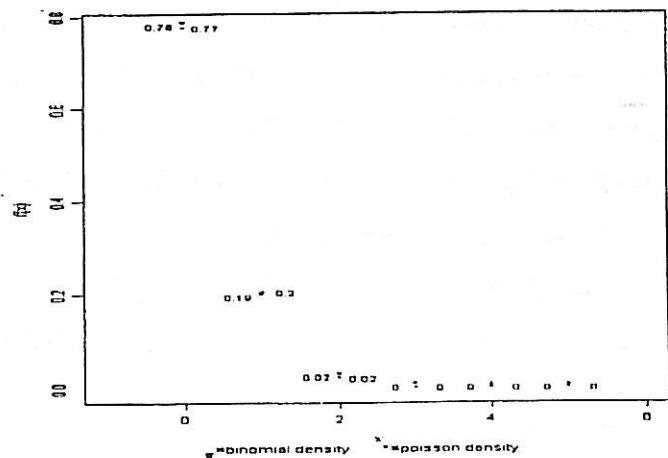
با توجه به منحنی تراز به ازای هر  $0.4 < p < 0$  می‌توان مقدار  $n$  متضطررا که به ازای آن تقریب مناسب است مشخص نمود. برای این منظور کافی است یک خط افقی از  $p$  به منحنی تراز  $\text{rmsd} = 0.005$  رسم شود و از آنجا خطی به محور  $n$  عمود شود؛ مثلاً اگر  $p = 0.21$  باشد به ازای  $n \geq 41$  تقریب دوجمله‌ای به پواسن مناسب خواهد بود.

نتایج به دست آمده از این نمودار مطابق با نتایج بررسی جدول ۱ است با این تفاوت که  $p$  بطور گستره با تغییرات  $0.05$  و  $n$  با تغییرات ۵ واحدی مدرج شده است، در حالی که در شکل ۲ تغییرات  $n$  و  $p$  بطور پیوسته قابل ملاحظه است. علاوه بر این به دلیل ماهیت نموداری بودن، تفسیر این نمودار راحت‌تر از جدول می‌باشد.

#### ۴. بحث و نتیجه‌گیری

در این مقاله به منظور بررسی عملی گرایش توزیع دوجمله‌ای به پواسن، میانگین اختلاف دو توزیع به ازای مقادیر مختلف  $\lambda$ ، در قالب ملاک «جذر میانگین مربع اختلافات» یا  $\text{rmsd}$  برای دامنه وسیعی از  $n$  و  $p$ ‌ها محاسبه شد و نتایج به صورت جدول و نمودار نمایش داده شد. نتایج بررسی مقادیر  $\text{rmsd}$  نشان داد چنانچه  $p$  کمتر یا مساوی  $0.10$  باشد برای  $n \geq 5$  می‌توان از تقریب دوجمله‌ای به پواسن استفاده نمود. همچنین اگر  $p$  بین  $0.10 \leq p < 0.20$  باشد برای  $n$ ‌های بزرگتر یا مساوی  $20$

شکل ۱- نمودار احتمالات توزیع‌های دوجمله‌ای (.) و پواسن (\*) برای  $n = 5$  و  $p = 0.05$  و  $0.25$

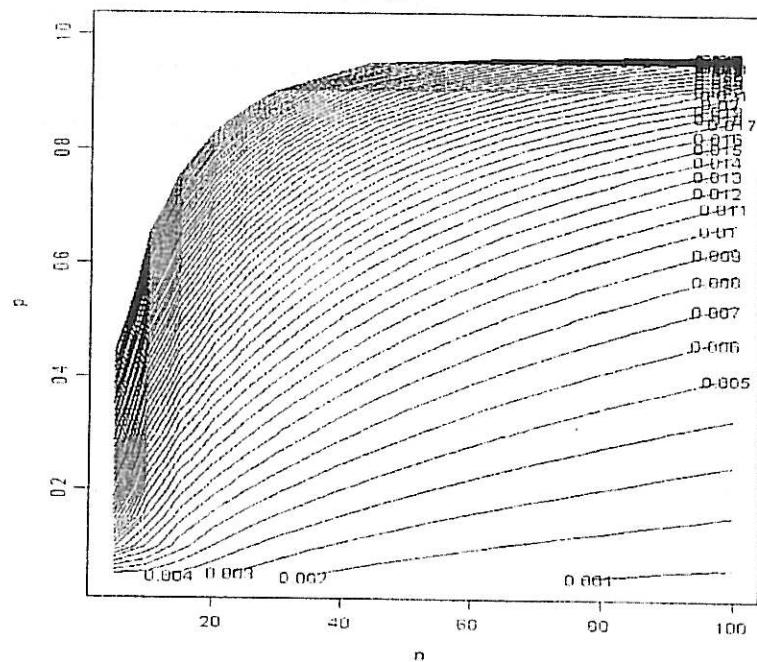


جدول (۱) مقادیر rmsd به ازای n و p های مختلف

p= 0.05 p= 0.1 p= 0.15 p= 0.2 p= 0.25 p= 0.3 p= 0.35 p= 0.4 p= 0.45 p= 0.5

n= 5	0.0044	0.0123	0.0197	0.0258	0.0309	0.0354	0.0403	0.0455	0.0511	0.0572
n= 10	0.0043	0.0090	0.0120	0.0146	0.0174	0.0205	0.0238	0.0273	0.0311	0.0353
n= 15	0.0038	0.0064	0.0084	0.0105	0.0127	0.0151	0.0176	0.0202	0.0231	0.0263
n= 20	0.0031	0.0050	0.0067	0.0084	0.0103	0.0122	0.0142	0.0164	0.0187	0.0213
n= 25	0.0026	0.0041	0.0056	0.0071	0.0087	0.0103	0.0120	0.0139	0.0159	0.0181
n= 30	0.0023	0.0035	0.0049	0.0062	0.0076	0.0090	0.0105	0.0121	0.0139	0.0158
n= 35	0.0020	0.0031	0.0043	0.0055	0.0067	0.0080	0.0094	0.0108	0.0124	0.0141
n= 40	0.0017	0.0028	0.0039	0.0050	0.0061	0.0072	0.0085	0.0098	0.0112	0.0128
n= 45	0.0016	0.0026	0.0036	0.0046	0.0056	0.0066	0.0078	0.0090	0.0103	0.0117
n= 50	0.0014	0.0024	0.0033	0.0042	0.0051	0.0061	0.0072	0.0083	0.0095	0.0108
n= 55	0.0013	0.0022	0.0031	0.0039	0.0048	0.0057	0.0067	0.0077	0.0088	0.0101
n= 60	0.0012	0.0021	0.0029	0.0037	0.0045	0.0053	0.0063	0.0072	0.0083	0.0094
n= 65	0.0012	0.0019	0.0027	0.0035	0.0042	0.0050	0.0059	0.0068	0.0078	0.0089
n= 70	0.0011	0.0018	0.0025	0.0033	0.0040	0.0048	0.0056	0.0064	0.0074	0.0084
n= 75	0.0010	0.0017	0.0024	0.0031	0.0038	0.0045	0.0053	0.0061	0.0070	0.0080
n= 80	0.0010	0.0017	0.0023	0.0030	0.0036	0.0043	0.0050	0.0058	0.0067	0.0076
n= 85	0.0009	0.0016	0.0022	0.0028	0.0035	0.0041	0.0048	0.0056	0.0064	0.0073
n= 90	0.0009	0.0015	0.0021	0.0027	0.0033	0.0039	0.0046	0.0053	0.0061	0.0070
n= 95	0.0009	0.0014	0.0020	0.0026	0.0032	0.0038	0.0044	0.0051	0.0059	0.0067
n= 100	0.0008	0.0014	0.0019	0.0025	0.0031	0.0036	0.0043	0.0049	0.0057	0.0064

شکل (۲)



## مراجع

- [۱] بهبودیان، جواد؛ ۱۳۷۷، آمار و احتمال مقدماتی، مؤسسه چاپ و انتشارات آستان قدس رضوی.
- [۲] راس، شلدون ام؛ ۱۳۷۶، نخستین درس احتمال، ترجمه دکتر حسنعلی آذرنوش، ابوالقاسم بزرگنیا، علی مشکانی و حسینعلی نیرومند، مؤسسه چاپ و انتشارات دانشگاه فردوسی مشهد.
- [۳] رضایی، عبدالمجید؛ ۱۳۸۰، مقاییم آمار و احتمالات، نشر مشهد، چاپ دوم.
- [۴] فروند، جان و والپول، رانلد؛ ۱۳۷۱، آمار ریاضی، ترجمه دکتر علی عمیدی، چاپ دوم، مرکز نشر دانشگاهی.
- [۵] نتر، جان و واسمن، ویلیام؛ ۱۳۷۳، آمار کاربردی، ترجمه دکتر علی عمیدی، چاپ اول، مرکز نشر دانشگاهی.
- [۶] مؤمنی، رضا؛ ۱۳۸۲، بررسی تجربی گرایش توزیع دوچمراهی به پواسن، پژوهه کارشناسی آمار، دانشگاه بیرجند.
- [۷] نعمتاللهی، نادر؛ ۱۳۸۱، آمار و احتمال مهندسی، انتشارات دلفک.