

بسمه تعالیٰ

دانشگاه شهید بهشتی

۱۴۲۱ / ۷ / ۱۵

دانشکده علوم ریاضی - گروه آمار

پایان نامه جهت دریافت درجه کارشناسی ارشد آمار

موضوع:

نظریه همپستگی الگوریتمیک

(و)

همپستگی تابعی و ختمی همپستگی

استاد راهنما:

آقای دکتر سیامک نوربلوچی

استاد مشاور:

آقای دکتر محمد رضا مشکانی

استاد داور:

آقای دکتر عبدالرحیم شهرلایی

نگارش:

محمد رضا ادرaki

شهریور ۱۳۷۷

۲۹۱۶

## تقدیم به:

خانواده عزیزم که همواره مرا در تمام  
مراحل زندگی یاری کرده‌اند.

سید جمال الدین

تاریخ

شماره

پیوست

## مورد جلسه دفاع از پایان نامه

جلسه هیئت داوران ارزیابی پایان نامه آقای / خالد محمد رضا ابراهی  
 به شناسمه شماره ۱۰۵ مادره از مشهد متولد ۱۳۴۱/۱/۱۵  
 دانشجوی دوره کارشناسی ارشد ناپیوسته رشته آمار-محض  
 با عنوان نظریه همبستگی کلاسیک و نظریه همبستگی ناهمگن و خمهای همبستگی  
 به راهنمائی دکتر سیامک نورپلوجی طبق دعوت قبلی در تاریخ ۷۵/۶/۲۱  
 تشکیل گردید و برآسان رای هیئت داوری و با عنایت به ماده ۴ آئین  
 نامه کارشناسی ارشد مورخ ۶۸/۸/۲۸ پایان نامه مذبور با نمره هیجده تمام  
 و درجه عالی مورد تمویب قرار گرفت.

استاد راهنمای  
استاد مشاور  
داور

- ۱- آقای دکتر سیامک نورپلوجی
- ۲- " " محمد رضا مشکانی
- ۳- " " عبدالرحیم شهرلایی
- ۴-
- ۵-

## \* فصل اول : مقدمه و کلیات

۱	۱. پیدایش و تکامل نظریه همبستگی .....
۹	۲.۱. مفهوم ضریب همبستگی و روش‌های نگرش به آن .....
۱۳	۲.۲. تعبیرهای مختلف ضریب همبستگی .....
۱۳	۲.۳.۱. همبستگی به صورت تابعی از اندازه‌های خام و میانگینها .....
۱۴	۲.۳.۲. همبستگی به صورت کواریانس استاندارد شده .....
۱۴	۳.۳.۱. همبستگی به صورت شب استاندارد شده خط رگرسیون .....
۱۶	۴.۳.۱. همبستگی به صورت میانگین هندسی دو شب رگرسیون .....
۱۷	۵.۳.۱. همبستگی به صورت جذر نسبت دو واریانس .....
۱۸	۶.۳.۱. همبستگی به صورت میانگین حاصلضرب متقاطع متغیرهای استاندارد شده .....
۱۸	۷.۳.۱. همبستگی به صورت تابعی از زاویه بین دو خط رگرسیونی استاندارد شده .....
۱۹	۸.۳.۱. همبستگی به صورت تابعی از زاویه بین دو بردار متغیر .....
۲۰	۹.۳.۱. همبستگی به صورت یک واریانس تجدید مقیاس شده از اختلاف بین اندازه‌های استاندارد شده .....

## صفحه

## عنوان

۲۱	۱۰.۳.۱. همبستگی برآورده از روی قاعده بادکنک
۲۱	۱۱.۳.۱. همبستگی در ارتباط با بیضیهای دو متغیره هم تراز
۲۳	۱۲.۳.۱. همبستگی به صورت تابعی از آماره آزمونی از آزمایشها طرح شده
۲۴	۱۳.۳.۱. همبستگی به صورت نسبت دو میانگین
۲۷	منابع فصل اول

## \* فصل دوم : توزیع نرمال دو متغیره و برآورد درستنمایی ماکزیمم ضریب همبستگی

۳۰	۱.۲. مقدمه
۳۰	۲.۲. توزیع نرمال دو متغیره
۳۳	۳.۲. برآوردهای درستنمایی ماکزیمم بردار میانگین و ماتریس کواریانس
۳۷	۴.۲. آماره‌های کافی (بسنده)
۳۷	۵.۲. تفسیر هندسی ضریب همبستگی پرسون
۴۲	۶.۲. معرفی برآوردهایی ناریب برای $\mu$ و $\Sigma$
۴۴	منابع فصل دوم

## عنوان

## صفحه

### \* فصل سوم:تابع توزیع ضرایب همبستگی نمونه

۴۵ .....	۱.۳. مقدمه
۴۵ .....	۲.۳. محاسبه توزیع ضرایب همبستگی پیرسون
۴۵ .....	۲.۲.۱. توزیع ضریب همبستگی نمونه در حالت دو متغیره وقتی $\rho = 0$
۵۰ .....	۲.۲.۲. توزیع ماتریس همبستگی نمونه
۵۱ .....	۳.۳. توزیع ضریب همبستگی نمونه، وقتی $\rho \neq 0$
۵۸ .....	۴.۳. برآورده نااریب برای $\rho$
۶۱ .....	۵.۳. توزیع مجانبی ضریب همبستگی نمونه‌ای از توزیع بیضوی
۶۵ .....	۶.۳. آزمون فرض ضرائب همبستگی جامعه
۶۶ .....	۶.۳.۱. آزمون فرض $i \neq j, \rho_{ij} = 0$
۶۷ .....	۶.۳.۲. آزمون فرض $H_0: \rho = \rho_0$
۷۰ .....	۶.۳.۳. آزمون فرض بوسیله تبدیل $Z$ فیشر
۷۰ .....	۶.۳.۴. آزمون فرض $H_0: \rho = \rho_0$
۷۱ .....	۶.۳.۵. آزمون فرض $H_0: \rho_1 = \rho_2$

۷۲ ..... منابع فصل سوم

**\* فصل چهارم: استنباط بیزی و محاسبه توزیع پسین ضریب همبستگی**

۷۳ ..... ۱.۴. مقدمه

۷۴ ..... ۲.۴. قاعده جفریز

۷۵ ..... ۱.۲.۴. پیشین جفریز

۷۸ ..... ۳.۴. نظریه ضریب همبستگی

۷۹ ..... ۱.۳.۴. توزیع پسین تقریبی ضریب همبستگی

۸۶ ..... ۲.۳.۴. توزیع پسین ضریب همبستگی

۹۰ ..... منابع فصل چهارم

**\* فصل پنجم: خم‌های همبستگی**

۹۱ ..... ۱.۵. مقدمه

۹۴.....	۲.۵. اندازه‌گیری قدرت ارتباط (خم همبستگی)
۹۴.....	۱.۲.۵. انگیزه‌ای برای استفاده از همبستگی موضعی
۹۶.....	۲.۲.۵. محاسبه همبستگی موضعی
۱۰۰.....	۳.۲.۵. خم همبستگی چندگانه
۱۰۲.....	۳.۵. برآورد خم همبستگی به روش نزدیکترین $K$ همسایه ( $K\_NN$ )
۱۰۲.....	۱.۳.۵. تعریف برآورد نزدیکترین $K$ همسایه
۱۰۵.....	۲.۳.۵. آماره‌های برآورد $K\_NN$
۱۰۷.....	۳.۳.۵. برآورد خم همبستگی
۱۱۰.....	۴.۳.۵. توزیع مجاذبی ( $\hat{p}(x)$ )
۱۱۱.....	۴.۵. برآورد خم همبستگی به روش نزدیکترین $K$ همسایه بوسیله نرم افزار $S\_PLUS$
۱۱۱.....	۱.۴.۵. برآورد خم همبستگی به روش $K\_NN$ برای داده‌های تولید شده از مثال ۱.۵
۱۱۷.....	۲.۴.۵. برآورد خم همبستگی به روش $K\_NN$ برای داده‌های مدل تبدیل یافته
۱۲۲.....	منابع فصل پنجم
۱۲۳.....	پیوست

## پیشگفتار:

با این که بیش از یک قرن از معرفی مفهوم همبستگی می‌گذرد و در طی این مدت معبارهای زیادی برای اندازه‌گیری شدت ارتباط بین دو متغیر ارائه شده است، ضریب همبستگی گشتاور حاصلضرب پیرسونی، هنوز جایگاه خود را حفظ کرده است. ضریب همبستگی پیرسون، درسیاری از زمینه‌ها، برای آزمایش‌های مبتنی بر مشاهدات، یک ابزار قوی آماری، برای اندازه‌گیری شدت رابطه خطی بین دو متغیر، محسوب می‌شود. در این تحقیق تکامل نظریه همبستگی را بطور اعم و ضریب همبستگی پیرسون را بطور اخْص (در توزیع نرمال دو متغیره)، مورد بحث قرار داده‌ایم. نهایتاً، خم همبستگی، که همبستگی ناهمگن را برحسب واریانس تبیین شده بوسیله رگرسیون برای هر مقدار متغیر مستقل، موضعاً محاسبه می‌کند را معرفی کرده‌ایم.

الفصل اول را به تکامل نظریه همبستگی و تاریخچه آن اختصاص داده‌ایم.

منابع اصلی این فصل پیرسون (۱۹۹۰)، بیرشک (۱۳۷۵) و عمیدی (۱۳۶۸) می‌باشد، که جهت کامل کردن رساله از آنها استفاده کرده‌ایم.

در فصل دوم برآورده درستنمایی ماکسیمم ضریب همبستگی از جامعه‌ای نرمال دو متغیره، را بدست آورده‌ایم و تفسیری هندسی از آن، به عنوان تابعی از زاویه بین دو بردار مشاهده، ارائه داده‌ایم. مطالب این فصل بیشتر جهت یادآوری هستند، منبع اصلی این فصل اندرسون (۱۹۸۴) می‌باشد.

در فصل سوم توزیع ضریب همبستگی پیرسون را بدست آورده‌ایم و نشان داده‌ایم که ضریب همبستگی

پیرسون، برآورده‌گری ارب برای  $\rho$ ، می‌باشد. همچنین برای ضریب همبستگی جامعه،  $\mu$ ، نظریه آزمون

فرضیه‌های کلاسیک را ارایه کرده‌ایم.

فصل چهارم را به استنباط بیزی برای ضریب همبستگی در جامعه نرمال اختصاص داده‌ایم و توزیع تقریبی و

دقیق ضریب همبستگی را با فرض پیشین مرجع و پیشین جفریز بدست آورده‌ایم.

در فصل پنجم، خم همبستگی را معرفی کرده‌ایم و برآورد نزدیکترین  $k$  همسایه را برای  $4000$  زوج مشاهده

ازیک مدل نظری (مثال ۱.۵)، و سپس برای مجموعه داده‌های مدل تبدیل یافته محاسبه کرده‌ایم. منبع اصلی

این فصل داکسام (۱۹۹۴) می‌باشد.

## «فصل اول»

### مقدمه و کلیات

#### ۱.۱. پیدایش و تکامل نظریه همبستگی

گالتون<sup>(۱)</sup> (۱۸۸۹)، از نخستین کسانی است که کارهایی درباره تعریف مفاهیمی چون همبستگی<sup>(۲)</sup> و برگشت<sup>(۳)</sup> (رگرسیون) انجام داده است و شیوه‌هایی برای اندازه‌گیری تاثیرات وراثت عرضه کرده و ابزارهایی برای این منظور فراهم آورده است. در واقع گالتون پدیده آماری رگرسیون را در حدود سال ۱۸۷۵، در جریان آزمایشها<sup>(۴)</sup> که با بذر نخود برای تعیین قانون وراثت در طول و وزن انجام می‌داد، کشف کرد. وی با استفاده از ۱۰۰ بذر ماده، از هفت رده که از روی اندازه‌های قطر آنها معین کرده بود و اعداد بدست آمده از هر رده از زاده‌های جدید، متوجه شد که میانگین قطر بذرهای زاده هر رده از بذرهای ماده، تقریباً بر روی یک خط راست واقع می‌شوند. علاوه بر این، میانگین قطر زاده‌های ماده‌های بزرگتر، کوچکتر از میانگین قطر بذرهای ماده، و میانگین قطر زاده‌های کوچکتر از میانگین قطر رده ماده بزرگتر بوده‌اند، و این امر از گرایش اندازه‌های «میانگین» قطر زاده‌ها به «برگشت» به اندازه‌ای می‌نمود که شاید بتوان آن را میانگین قطر اجدادی نامید. وی ابتدا این

<sup>۱</sup>-Galton , F

<sup>۲</sup>-Correlation

<sup>۳</sup>-Regression

پدیده را «عکس<sup>(۱)</sup>» و سپس آن را «رگرسیون» نامید.

وی با استفاده از شیوه‌هایی که برای اندازه‌گیری تاثیر و راثت بکار می‌برد، در مساله اندازه‌گیری درجه وابستگی<sup>(۲)</sup> میان اندازه‌ی دو اندام متفاوت یک فرد، به مفهومی از «ضریب هم رابطگی» رسید که اندازه‌ای از درجه بستگی میان دو ویژگی بود، و تشخیص داد که ۲ اندازه «عکس» یا «رگرسیون»، مضری از این گونه هم رابطگی<sup>(۳)</sup> یا همبستگی است که کاربرد وسیعی دارد. به سبب پیچیدگی ریاضیات مورد نیاز برای مطالعه همبستگی و رگرسیون، گالتون نتوانست صورت بندهی ریاضیاتی این مفاهیم را بیابد. اما پیرسون<sup>(۴)</sup> از پس این کار برآمد.

در ۱۸۹۲ پیرسون درباره تغییرات و همبستگی، سخنرانی کرد و سخنانش در «مذاکرات فلسفی<sup>(۵)</sup>» (۱۹۰۲) انتشار یافت.

در آن زمان وی مشغول یافتن نظریه عمومی همبستگی نرمال برای سه، چهار و  $n$  متغیر بود، و آرام آرام به سوی نظریه کلی همبستگی چوله<sup>(۶)</sup> و رگرسیون غیرخطی پیش می‌رفت که تا سال ۱۹۰۵ انتشار نیافت.

همان گونه که مفهومها و شیوه‌های همبستگی و رگرسیون را گالتون معرفی کرد و روش‌های مقدماتی حسابی و ترسیمی را (با استفاده از بعضی میانه‌ها و چارکهای داده‌هایی که در دست بود) برای بدست آوردن ضریب رگرسیون با «شاخص همبستگی»،<sup>۷</sup> بر اساس یک نمونه طرح ریزی کرد؛ پیرسون،

۱-Reversion

۲-association

۳-Co\_relatio

۴-pearsor,k

۵-philosophical Transactions

۶-skew correlation

بوسیله آنچه امروز اصطلاح روش درستنمایی ماکسیمم<sup>(۱)</sup> نامیده می‌شود، نشان داد که «بهترین برآورد ضریب همبستگی» (پ) برای یک توزیع نرمال دو متغیری توسط ضریب همبستگی حاصل ضرب گشتاور نمونه‌ای

$$r = \frac{\sum xy}{NS_x S_y} = \frac{\sum xy}{\sqrt{\sum x^2 \sum y^2}}$$

بدست می‌آید. اصطلاح «ضریب همبستگی» را ظاهراً اج ورت در ۱۸۹۲ بکاربرده است، اما مقدار ۲، که با معادله بالا داده شده به «ضریب همبستگی پیرسون» معروف است. به عنوان مثال می‌توان به مقاله «رگرسیون، وراثت، تولید مثل ایلخی (یا آمیزش بی حق انتخاب [panmixia]) (۱۸۹۶)» که نخستین مقاله اساسی پیرسون درباره نظریه همبستگی و کاربرد آن در نظریه وراثت بود مراجعه نمود. در مقاله فوق پیرسون نشان داده است که چگونه ممکن است «بهترین مقدار» ۲ را به نحوی مناسب از انحرافهای معیار نمونه  $S_x$  و  $S_y$  و یکی از هر دو مقدار  $-S_x$  یا  $-S_y$  برآورد کرد و از محاسبه گشتاور حاصل ضرب نمونه  $\frac{\sum xy}{N}$  پرهیز نمود.

وی در بحثی که در حالت سه متغیری پیش کشید، آنچه که امروزه ضرایب همبستگی «چندگانه» و «جزئی» نامیده می‌شود را به صراحة بر حسب سه ضریب همبستگی ۳۱۲ و ۳۲۳ و ۳۳۲ بیان کرد. فرمول اج ورت (۱۸۹۲) برای توزیع نرمال سه متغیری را بصورتی بهتر و با نمایش ماتریسی از نو بیان کرد و آنرا به حالت همبستگی نرمال  $p$  متغیره بسط داد و به صورتی درآورد که محاسبات را در

حیطه توانایی کسانی قرارداد که فاقد ورزیدگی در ریاضیات پیشرفته هستند.

در مقاله فوق بیان کرده است هرگاه توزیع مشترک تعدادی از متغیرهای  $X_1, X_2, \dots, X_p$

( $p \geq 2$ ) توزیع نرمال چند متغیری باشد، آنگاه ضرایب همبستگی جامعه یعنی  $\rho_{ij}$

و  $i \neq j$  ( $i, j = 1, 2, \dots, p$ ) درجات همبستگی میان این خصلتها را در جامعه نشان می‌دهند. متغیرهای

$X_i$  و  $X_j$  مستقل از یکدیگرند اگر و فقط اگر  $\rho_{ij} = 0$  و کاملاً به یکدیگر وابسطه‌اند اگر و فقط اگر  $\rho_{ij} = \pm 1$ .

نظریه عمومی همبستگی چندگانه و جزئی راج. آدنی یول، دستیار ریاضی او، در دو مقاله در ۱۸۹۷

ادامه داد. یول اولین کسی بود که برای ضرایب همبستگی جزئی، که خودش برای آنها اصطلاح

«ضرایب همبستگی خالص» را بکار می‌برده است، صورت ریاضی بیان نمود.

بر آنچه پیرسون ضرایب رگرسیون دوگانه نامیده بود، یول نام رگرسیونهای خالص گذاشت، که اکنون

آنها را ضرایب رگرسیون جزئی می‌نامند.

منشا اصطلاحات «همبستگی چندگانه» و «همبستگی جزئی» مقاله‌ای است که پیرسون، با لیس لی

نوشت و در ۱۸۹۷ در انجمن سلطنتی فرائت کرد.

پیرسون سعی فراوانی نمود تاروشهای همبستگی را به داده‌های دو متغیری که بر حسب هر خصلت

به دو طبقه، یا بیشتر، طبقه‌بندی شده بودند تعمیم دهد. وی (در ۱۹۰۰) در مقاله «همبستگی

خصلتها یی که از جنبه کمیّتی قابل اندازه‌گیری نیستند» ضریب  $\rho$ <sup>۱</sup> که موسوم به «ضریب چهار

دسته‌ای<sup>(۲)</sup> است را معرفی کرد.

<sup>۱</sup>-tetrachoric

استودنت (و.س. گوست<sup>(۱)</sup>، ۱۹۰۷)، استنباط کرده بود که در نمونه های تصادفی با اندازه  $n \geq 2$ ، از توزیع نرمال دو متغیری، توزیع  $\chi^2$  به صورت متقارن در حول صفر توزیع می شود. استودنت در مقاله دیگری با عنوان، «خطاهای احتمالی میانگین» که در ۱۹۰۸ منتشر ساخت، توزیع  $\chi^2$  را در نمونه های تصادفی از توزیع نرمال دو متغیری بدست آورد. این کشفها جوانه های علمی و تجربی بود که «استودنت» در آزمایشگاه زیست سنجی پیرسون در لندن بدست آورده بود. اما پیرسون و همکارانش هیچ علاقه ای به بسط نظریه آماری و شیوه های خاص تحلیل نتایج آزمایش های کوچک نمونه ای نداشتند.

در ۱۹۱۴ دستنویس مقاله ای به پیرسون رسید که در آن ر.ا. فیشر<sup>(۲)</sup> توزیع نمونه ای  $\chi^2$  را در نمونه های با هر اندازه  $n \geq 2$  و از جامعه نرمال دو متغیری با هر درجه همبستگی  $1 - \rho \leq 1 + \rho \leq 0$  بدست آورده بود. پیرسون از این نوشه با شور و شوق استقبال کرد و به فیشر «از ته دل برای توفیق در بدست آوردن صورت فعلی توزیع  $\chi^2$  شادباش گفت و اظهار داشت که «هرگاه تحلیل، چنان که بسیار محتمل است، درست باشد، وی از انتشار مقاله در مجله بیومتریکا بسیار مسرور خواهد شد». یک هفته بعد به فیشر نوشت: «اکنون من مقاله شما را کاملاً خوانده ام و فکر می کنم که از پیشرفتی بسیار ممتاز نشان داشته باشد... از منتشر ساختن آن بسیار مسرور خواهم شد... مقاله در شماره آینده (مه ۱۹۱۵) منتشر خواهد شد... ای کاش وقت داشتید که صفحات آخر را کمی بسط دهید... دوست دارم شاهد کوششی باشم برای تعیین آنکه به ازای چه مقدارهای  $M$  می توانیم فرض کنیم که توزیع عملی نرمال است».