




بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

٣/٤٤٢



# همگرایی ضعیف فرایندهای تجربی و آزمون نیکویی برازش برای مدل‌های پارامتری

تألیف

مریم قدسی

رساله ارائه شده به عنوان بخشی از ملزومات برای دریافت درجه

کارشناسی ارشد آمار

تأیید

دکتر محمد قاسم وحیدی اصل

استاد مشاور

دکتر خلیل شفیعی

9008 -

دانشکده علوم ریاضی

دانشگاه شهید بهشتی

شهریورماه ۱۳۷۹

۳۱۴۴۰

صور تجلسه دفاع از پایان نامه

جلسه هیأت داوران ارزیابی پایان نامه خانم مریم قدسی

به شماره شناسنامه: ۶۳۳ صادره از: شیراز متولد: ۱۳۵۳ دانشجوی دوره

کارشناسی ارشد ناپیوسته رشته: آمار

با عنوان: همگرایی فرآیند تجربی پارامتری تعمیم یافته و آزمونهای نیکویی برازش برای  
مدلهای پارامتری

به راهنمایی: آقای دکتر محمد قاسم وحیدی اصل طبق دعوت قبلی در تاریخ ۲۹/۶/۱۳

تشکیل گردید و براساس رأی هیأت داوران و با عنایت به ماده ۲۰ آئین نامه کارشناسی

ارشد مورخ ۷۳/۱۰/۲۵ پایان نامه مزبور با نمره ۱۹ (نوزده تمام) و درجه عالی

مورد تصویب قرار گرفت.

۱- آقای دکتر محمد قاسم وحیدی اصل

۲- آقای دکتر خلیل شفیعی

۳- آقای دکتر علی عمیدی

۴- آقای دکتر احمد خدادادی

-۵

استاد راهنما

استاد مشاور

استاد داور

استاد داور

## قدردانی

در این جا لازم است از کلیه افرادی که مرا در انجام این پایان نامه کمک نموده‌اند، خصوصاً از اساتید گرامی جناب آقای دکتر محمد قاسم وحیدی اصل و سرکار خانم دکتر زهره شیشه‌بر که در تمام مراحل انجام این پایان نامه با مساعدت‌ها و راهنمایی‌های بی دریغ خود مرا یاری کردند، تشکر کنم.

## همگرایی ضعیف فرایندهای تجربی و آزمون نیکویی برازش برای مدل‌های پارامتری

### چکیده

می‌خواهیم توزیع یک سری داده خام را مشخص نماییم. برای این منظور از آزمونهای معنی‌داری سود برده، ابتدا آماره آزمون و سپس توزیع آن را تحت مدل فرض شده به دست می‌آوریم. از همگرایی ضعیف فرایندهای تجربی استفاده کرده و برای دو نوع داده، داده‌های بدون سانسور (کامل) و سانسور شده، آزمون را انجام می‌دهیم. برای داده‌های کامل یا بدون سانسور، آماره کولموگروف-اسمیرنوف بهترین آماره می‌باشد.

برای داده‌های زمان شکست، برآورد کاپلان-مایر تعمیم‌یافته  $F_n(t)$  را با تابع توزیع برآورد شده  $F(t, \hat{\theta})$  تحت مدل فرض شده، که  $\hat{\theta}$  برآورد ماکزیمم درست‌نمایی است، مقایسه می‌کنیم. فرایند تجربی پارامتری تعمیم‌یافته  $\sqrt{n}(F_n(t) - F(t, \hat{\theta}))$  توسط انتگرالهای تصادفی نسبت به یک مارتینگل تقریب زده می‌شود. این در توزیع به یک فرایند گاوسی همگراست که می‌تواند، توسط انتگرالهای تصادفی نسبت به یک حرکت براونی نمایش داده شود. همگرایی ضعیف فرایند تجربی پارامتری روی خط کلی برای داده‌های سانسور شده تصادفی به دست آورده می‌شود. از طریق تبدیل فرایند گاوسی حدی به یک مارتینگل گاوسی، آزمونهای خوبی برازندگی را برای مدل‌های پارامتری به دست می‌آوریم.

واژه‌های کلیدی: آزمون کولموگروف-اسمیرنوف، برآورد کاپلان-مایر تعمیم‌یافته، تبدیل، تقریب مارتینگل، حرکت براونی، داده سانسور شده.

# فهرست مندرجات

۵	مقدمه	۱
۹	تعريف‌ها و پيش‌نيازها	۲
۹	۱.۲ عنصر تصادفی و فرايندهای تصادفی خاص	۱.۲
۱۴	۲.۲ تعريف‌های مورد نیاز	۲.۲
۱۴	۱.۲.۲ پالایش و زمان توقف	۱.۲.۲
۱۷	۲.۲.۲ چند مفهوم اصلی	۲.۲.۲
۱۹	۳.۲.۲ مارتینگل پیوسته	۳.۲.۲
۲۲	۳.۲ همگرایی ضعیف	۳.۲
۲۲	۱.۳.۲ فضای توپولوژی	۱.۳.۲
۲۲	۲.۳.۲ همگرایی ضعیف	۲.۳.۲
۲۷	۴.۲ انتگرال تصادفی	۴.۲
۲۹	۵.۲ دونا برابری	۵.۲
۳۱	فرايندهای تجربی	۳

۳۱	.....	فرایند تجربی	۱.۳
۳۳	.....	فرایند تجربی پارامتری تعمیم یافته	۲.۳
۳۴	.....	برآورد تابع بقا	۱.۲.۳
۳۷	.....	تعریف فرایند تجربی پارامتری تعمیم یافته	۲.۲.۳
۳۸	.....	فرایندهای جبرانگر و شدت	۳.۳
۴۳	.....	دو کاربرد از فرایند شدت	۱.۳.۳
۴۴	.....	فرایندهای جبرانگر و شدت فرایندهای تجربی	۲.۳.۳

۴ همگرایی ضعیف فرایندهای تجربی

۵۰	.....	همگرایی ضعیف فرایند تجربی	۱.۴
۵۱	.....	همگرایی ضعیف فرایند تجربی پارامتری تعمیم یافته	۲.۴
۵۱	.....	نمادها و فرضها	۱.۲.۴
۵۳	.....	همگرایی ضعیف فرایند تجربی پارامتری تعمیم یافته	۲.۲.۴
۵۶	.....	بسط همگرایی ضعیف به خط کلی	۳.۲.۴
۵۸	.....	برهان قضایا	۳.۴

۵ آزمونهای نیکویی برازش

۷۳	.....	مقدمه	۱.۵
۷۳	.....	تبدیلات	۲.۵
۷۶	.....	آزمونهای نیکویی برازش	۳.۵

۷۷ ..... ۴.۵ برهان قضایا

۸۲ A لیست نمادهای خاص

۸۶ B واژه‌نامه‌ی فارسی به انگلیسی

۸۹ C واژه‌نامه‌ی انگلیسی به فارسی



## لیست اشکال

۱.۲ در هر سه وضعیت (۱)، (۲) و (۳) فاصله اسکورخود بین تابع سمت چپ،  $x$ ، و سمت راست،  $y$ ، در رابطه  $d(x, y) = \epsilon$  صدق می‌کند. (مثال ۲-۱) را ملاحظه نمایید.)

۲۸

۱.۳ تابع توزیع تجربی و نظری

۳۲

## فصل ۱

# مقدمه

برای برآورد تابع توزیع مجموعه‌ای از داده‌ها، روشهای پارامتری و ناپارامتری متفاوتی به کار می‌روند. روشهای ناپارامتری تعداد محدودی بیش نیستند که در زیر آنها را می‌آوریم. فرض کنید  $X_1, X_2, \dots, X_n$  متغیرهای تصادفی و هم‌توزیع (i.i.d) باشند به طوری که

$$X \cong (\mu, \sigma^2)$$

یعنی توزیع  $X$ ، دارای میانگین  $\mu$  و واریانس  $\sigma^2$  است. همچنین فرض کنید

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

قانون قوی اعداد بزرگ (SLLN) می‌گوید که وقتی  $n \rightarrow \infty$

$$\bar{X}_n \xrightarrow{a.s.} \mu$$

(این رابطه بدون هیچ گونه فرضی در مورد واریانس برقرار است) پس هرگاه که  $n$  زیاد می‌شود و سیر صعودی پیدا می‌کند میانگین را از روی داده‌ها، با دقت، می‌توان برآورد کرد. ارزیابی دقت این تقریب توسط قضیه حد مرکزی داده می‌شود به طوری که وقتی  $n \rightarrow \infty$

$$\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma} \xrightarrow{d} N(0, 1) \quad (1-1)$$

سرعت همگرایی در (۱-۱) وقتی  $E|X|^2 < \infty$  به صورت

$$\sup_x |P\left(\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma} \leq x\right) - \Phi(x)| \leq \frac{23}{4} \frac{E|X - \mu|^2}{\sigma^2} \frac{1}{\sqrt{n}}$$

تعیین می‌شود که از نتیجه بری-اسن به دست می‌آید و  $\Phi$  تابع توزیع نرمال استاندارد می‌باشد.

یکی از مفیدترین نتایج نظریه احتمال قضیه من-والد است که برای هر تابع پیوسته  $g$  و با استفاده از (۱-۱) هنگامی که  $n$  به سمت بینهایت می‌رود، خواهیم داشت:

$$g\left(\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma}\right) \xrightarrow{d} g(N(0, 1))$$

به عنوان مثال وقتی  $n \rightarrow \infty$ ,

$$n\left(\frac{\bar{X}_n - \mu}{\sigma}\right)^2 \xrightarrow{d} \chi^2(1)$$

که البته این نتیجه کلی می‌باشد یعنی اگر

$$X_n \xrightarrow{d} X$$

آنگاه برای هر تابع پیوسته  $g$  داریم:

$$g(X_n) \xrightarrow{d} g(X)$$

قضایای دیگری نیز وجود دارند که سرعت همگرایی  $\bar{X}_n - \mu$  را به صفر ارائه می‌دهند، یکی از آنها قانون لگاریتم مکرر (LIL) است که وقتی  $n \rightarrow \infty$  می‌گوید:

$$\sqrt{n}(\bar{X}_n - \mu)/b_n \rightarrow [-\sigma, \sigma] \text{ a.s.}$$

که در آن  $b_n = \sqrt{2 \log(\log n)}$  و  $\rightarrow$  بدین معناست که برای تقریباً هر  $\omega$  (a.e.  $\omega$ ) در مجموعه  $\Omega$  از فضای احتمال اصلی  $(\Omega, \mathcal{F}, P)$  که متغیرهای تصادفی روی آن تعریف شده‌اند،

دنباله اعداد حقیقی  $\sqrt{n}(\bar{X}_n(\omega) - \mu)/b_n$  دارای نقاط حدی بازه  $[-\sigma, \sigma]$  می‌باشند. [۴۲]

قانون لگاریتم مکرر به صورت زیر داده می‌شود:

$$\lim_{n \rightarrow \infty} \max_{1 \leq k \leq n} \frac{1}{\sqrt{n}} \left| \sum_{i=1}^k (X_i - \mu) \right| b_n = \frac{\pi}{4} \text{ a.s.}$$

اگر  $X_1, X_2, \dots$  متغیرهای تصادفی *i.i.d* دلخواهی باشند، وقتی  $n \rightarrow \infty$  داریم:

$$n^{-1} \log P(\bar{X}_n \geq \circ) \rightarrow \log \rho$$

به طوری که

$$\rho = \inf_t M(t)$$

که  $M(t)$  تابع مولد گشتاوری است ( $M(t) = E(e^{tX})$ ) و بیشتر این که اگر  $X$ ، در شرطهای استاندارد

$$t^* = \sup\{t : M(t) < \infty\} \leq \infty, \quad M'(\circ^+) < \infty$$

و برای  $\circ < t < t^*$

$$M'(t) > \circ$$

صدق کند، نتیجه قوی تر زیر به دست خواهیم آورد:

$$P(\bar{X}_n \leq \circ) = \frac{\rho^n b_n}{\sqrt{n}}$$

که در آن  $\circ < \liminf b_n \leq \overline{\lim} b_n < \infty$  [۸].

مطالعه تابع توزیع تجربی با روشهای ناپارامتری فوق وسعت داده می شود، اما این روشهای ناپارامتری در بعضی از عملکردها کارا نیستند و تعداد این روشها به تعداد محدود معرفی شده در بالا خلاصه می شوند و شرایط بسیاری از مسائل با این روشها جور نمی باشند، بنابراین از روش جامع تر تابع توزیع تجربی استفاده می کنند. که قضیه گلیونکو-کانتلی<sup>۱</sup> نیکویی این برآورد را تصدیق می کند.

در بررسی داده های زمان شکست (مثلاً طول عمر یک لامپ) نیز توزیع فراوانی زمانهای بقا معمولاً از توزیع نرمال حتی با انجام تبدیل ساده ای هم فاصله دارد و تابع توزیع تجربی در این حالت، برآورد کاپلان-مایر می باشد که مستقیماً از روی داده ها به دست می آید و در بررسی الگوهای آماری مفید می باشد.

در این پایان نامه ابتدا فرایندهای تجربی را در حالت کلی تعریف کرده و فرایند تجربی پارامتری تعمیم یافته را که برای داده های زمان شکست است، ارائه می دهیم. که برای این منظور بایستی تا حدودی به مفاهیم آنالیز بقا آشنا باشیم بنابراین در بخش دوم فصل سوم به آن می پردازیم.

اغلب اوقات در حد، صحبت از خود متغیر امکان پذیر نیست، اما می توان از توزیع آن در حد صحبت کرد، برای این منظور از همگرایی ضعیف استفاده می نمایند. در فصل چهارم ابتدا همگرایی ضعیف فرایند تجربی به یک پل براونی و سپس همگرایی ضعیف فرایند تجربی پارامتری تعمیم یافته به یک فرایند گاوسی را بیان می کنیم که این فرایند گاوسی را می توان توسط انتگرالهای تصادفی نسبت به یک فرایند وینر نمایش داد.

در پایان از طریق تبدیل این فرایند گاوسی حدی به یک مارتینگل گاوسی، رده ای از آزمونهای نیکویی برازش برای مدل های پارامتری را ارائه می دهیم.

لازم به تذکر است که برای مطالعه این دفتر بایستی با مفاهیم اولیه فرایندهای تصادفی آشنا بود که ابتدای فصل دوم را به این بحث اختصاص داده ایم. همچنین همگرایی ضعیف فرایندهای تصادفی و انتگرال تصادفی ابزار کار ما در این جا می باشند و تا جایی که رفع ابهام نمایند در بخش سوم و چهارم از فصل دوم توضیح داده می شوند.

همچنین برهان و اثبات قضایا و لم هایی که در طول فصلها وجود دارند و طولانی می باشند، در پایان همان فصل مربوطه آورده می شوند.

## تعریف‌ها و پیش‌نیازها

## ۱.۲ عنصر تصادفی و فرایندهای تصادفی خاص

فرض کنید  $M$  مجموعه‌ای از تابعهای  $x$  باشد که هر  $t$  در مجموعه  $T$  را به عدد حقیقی  $x(t)$  مرتبط می‌کند.  $T$  معمولاً یک مجموعه اقلیدسی مانند  $[0, 1]$  و یا  $R$  است. برای هر عدد صحیح  $k \geq 1$  و هر  $t_1, \dots, t_k$  در  $T$ ، فرض کنید  $\pi_t = \pi_{t_1, \dots, t_k}$  نگاشت  $M$  به توی فضای  $k$ -بعدی  $R^k$  باشد که به صورت زیر تعریف می‌شود:

$$\pi_t(x) = \pi_{t_1, \dots, t_k}(x) = (x(t_1), \dots, x(t_k)). \quad (2-1)$$

آنگاه برای هر زیر مجموعه بورل در کلاس  $B^k$  از زیر مجموعه‌های بورل  $R^k$ ، مجموعه  $\pi_{t_1, \dots, t_k}^{-1}(B)$  یک «زیر مجموعه منتهای بعدی  $M$ » نامیده می‌شود. حال  $M$  که شامل همه زیر مجموعه‌های منتهای بعدی  $M$  می‌باشد لزوماً یک میدان است، چون در واقع می‌توان  $\pi_{t_1, \dots, t_k}^{-1}(B)$  را به صورت

$$\pi_{t_1, \dots, t_k}^{-1}(B) = \{x \in M : (x(t_1), \dots, x(t_k)) \in B\}$$

نوشت.

فرض کنید  $M$  سیگما میدان تولید شده توسط میدان  $M$  از زیرمجموعه‌های منتهای بعدی باشد. برای چنین مجموعه  $M$ ، فضای اندازه‌پذیر  $(M, \mathcal{M})$  را فضای تابعی اندازه‌پذیر

روی  $T$  می‌نامیم. یک نگاشت اندازه‌پذیر از فضای احتمال  $(\Omega, \mathcal{F}, P)$  به یک فضای تابعی اندازه‌پذیر (یا به یک فضای اندازه‌پذیر دلخواه) را عنصر تصادفی روی (یعنی مجموعه‌ی مقادیر خود را در) این فضای اندازه‌پذیر می‌نامند.

تعریف (۱-۲). عنصرهای تصادفی روی فضاهای تابعی اندازه‌پذیر را همچنین یک فرایند تصادفی می‌نامند.

مسئله (۱-۲). فرض کنید  $B = B(R)$  زیر مجموعه‌های بورل خط حقیقی  $R$  باشد. آنگاه  $X$  یک فرایند تصادفی روی  $(M, \mathcal{M})$  است، اگر و فقط اگر برای هر  $\omega \in \Omega$ ،  $X(\cdot, \omega) \in M$  و برای هر  $t \in T$ ،  $X(t, \cdot)$  یک متغیر تصادفی روی  $(R, \mathcal{B})$  باشد.  $X$  یک متغیر تصادفی روی  $(R, \mathcal{B})$  نامیده می‌شود اگر و فقط اگر برای هر  $B \in \mathcal{B}$ ،  $X^{-1}(B) \in \mathcal{F}$ .

برهان. توجه می‌کنیم که  $X$  بایستی یک نگاشت اندازه‌پذیر از  $(\Omega, \mathcal{F}, P)$  به  $(M, \mathcal{M})$  باشد، به عبارت دیگر بایستی نگاشت

$$(t, \omega) \xrightarrow{X} X(t, \omega)$$

اندازه‌پذیر باشد یعنی

$$X^{-1}(B) \in \mathcal{F}$$

□ که از قضیه‌ی فویننی نتیجه‌ی مورد نظر حاصل می‌گردد.

این عنصر تصادفی اندازه‌ی احتمال  $P_X$  را روی جفت  $(M, \mathcal{M})$  توسط رابطه‌ی

$$P_X(A) = P(X \in A) = P(X^{-1}(A)) \quad ; A \in \mathcal{M} \quad (۲-۲)$$

تولید می‌کند (برای زیر مجموعه‌های متناهی بعدی  $A$ ).

دو متغیر تصادفی  $X$  و  $Z$  را «هم‌ارز» می‌نامند اگر دارای توزیعهای یکسان باشند. دو فرایند  $X$  و  $Z$  دارای توزیعهای متناهی بعدی یکسان هستند اگر  $P_X$  و  $P_Z$  روی  $\mathcal{M}$  منطبق باشند. وقتی که  $X$  و  $Z$  دارای توزیعهای متناهی بعدی یکسان باشند، آنها را فرایندهای «هم‌ارز» می‌نامند.