

دانشگاه تربیت مدرس

دانشکده علوم ریاضی

پایان نامه دوره کارشناسی ارشد آمار

تحلیل مدل‌های ... با روش تقریب لاپلاس آشیانی ترکیبی

توسط

کبری قلیزاده
زهرا قیومی

استاد راهنما

دکتر محسن محمدزاده

تیر ماه ۱۳۹۱

فهرست مندرجات

۱ مفاهیم مقدماتی

۱	مقدمه	۱.۱
۱	تعاریف و مفاهیم اولیه	۲.۱
۳	استقلال شرطی	۱.۲.۱
۳	گراف	۲.۲.۱
۵	ماتریس همیشه مثبت متقارن	۳.۲.۱
۷	میدان تصادفی مارکوفی گاووسی	۳.۱
۹	خواص مارکوفی GMRF	۱.۳.۱
۱۱	ویژگی‌های شرطی میدان تصادفی مارکوفی گاووسی	۲.۳.۱
۱۲	مشخص‌سازی GMRF با شرطی‌های کامل	۳.۳.۱

الف

فهرست مندرجات

ب

۱۴	میدان تصادفی مارکوفی گاووسی چندمتغیره	۴.۳.۱
۱۵	الگوریتم‌های محاسباتی و شبیه‌سازی GMRF	۴.۱
۱۷	شبیه‌سازی غیرشرطی میدان تصادفی مارکوفی گاووسی	۱.۴.۱
۲۰	شبیه‌سازی شرطی میدان تصادفی مارکوفی گاووسی	۲.۴.۱
۲۳	روش‌های عددی برای ماتریس‌های ثُنک	۵.۱
۲۳	تجزیه یک ماتریس ثُنک	۱.۵.۱
۳۰	۲ میدان تصادفی مارکوفی گاووسی ذاتی	
۳۱	تعاریف و مفاهیم اولیه	۱.۲
۳۱	تفاضل پیشرو	۱.۱.۲
۳۲	چندجمله‌ای‌ها	۲.۱.۲
۳۴	میدان تصادفی مارکوفی گاووسی تحت قیدهای خطی	۲.۲
۳۹	میدان تصادفی مارکوفی گاووسی ذاتی مرتبه اول	۳.۲
۴۰	میدان تصادفی مارکوفی گاووسی ذاتی مرتبه اول روی خط	۱.۳.۲
۴۴	میدان تصادفی مارکوفی گاووسی ذاتی مرتبه اول روی مشبکه	۲.۳.۲

فهرست مندرجات

ج

۴۶ ۴.۲ میدان‌های تصادفی مارکوفی گاووسی ذاتی مرتب بالا

۴۷ ۱.۴.۲ میدان تصادفی گاووسی مارکوفی ذاتی مرتب بالاتر روی خط

۵۲ ۵.۲ مدل قدم زدن تصادفی زمان پیوسته

۳ تقریب لاپلاس آشیانی ترکیبی

۵۸ ۱.۳ تقریب گاووسی

۶۱ ۲.۳ تقریب لاپلاس

۶۲ ۱.۲.۳ میانگین و واریانس پسینی

۶۴ ۲.۲.۳ چگالی پسینی کناری

۶۴ ۳.۳ تقریب لاپلاس آشیانی ترکیبی

۶۵ ۱.۳.۳ تقریب پسینی توام بردار ابرپارامترها

۶۹ ۲.۳.۳ طرح مرکب مرکزی

۷۰ ۳.۳.۳ طرح

۷۴ ۴.۳.۳ محاسبه تقریب کناری عناصر بردار ابرپارامتر

۷۴ ۵.۳.۳ محاسبه تقریب کناری پسینی عناصر میدان پنهان

فصل ۱

مفاهیم مقدماتی

۱.۱ مقدمه

۲.۱ تعاریف و مفاهیم اولیه

در این پایان‌نامه بردارها و ماتریس‌ها به صورت برجسته، مانند x و A نشان داده می‌شوند. ترانهاده A با A^T مشخص می‌شود. نماد (A_{ij}) مشخص می‌کند که مولفه سطر i و ستون j ماتریس A است. همچنین مشابه این نماد نیز برای بردار استفاده می‌شود، به عبارتی (x_i) . $x = A_{i:j}$ کوتاه شده بردار x به صورت $(x_i, x_{i+1}, \dots, x_j)^T$ است. اگر $A_{n \times m}$ ماتریسی با m ستون n کوثر است، $Vec(A) = (A_{11}, \dots, A_{1m}, \dots, A_{n1}, \dots, A_{nn})$ برداری ستونی است که از زیر هم قرار دادن ستون‌های ماتریس A باشد، $Vec(A) = (A_{11}, \dots, A_{1m}, \dots, A_{n1}, \dots, A_{nn})$ ماتریسی که از حذف بعضی از سطرهای A به دست می‌آید زیرماتریس A حاصل می‌شود. زیرماتریسی را که از حذف سطر و ستون با اندیس یکسان به دست آید زیرماتریس A نامیده می‌شود. زیرماتریسی را که از حذف سطر و ستون با اندیس متفاوت به دست آید زیرماتریس $B = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}$ که از حذف سطر و ستون سوم ماتریس A اصلی گویند. به عنوان مثال، ماتریس

حاصل شده است یک زیرماتریس اصلی ماتریس A است. زیر ماتریس $r \times r$ ، که از حذف $n - r$ سطر و ستون آخر ماتریس A به دست می آید زیر ماتریس اصلی مقدم A^1 نامیده می شود.

اگر A ماتریس $n \times n$ و a برداری با $1 \times n$ باشد، آن‌گاه $diag(A)$ و (a) به ترتیب به منظور نمایش ماتریس‌های قطری

$$diag(\mathbf{A}) = \begin{pmatrix} A_{11} & & \\ & \ddots & \\ & & A_{nn} \end{pmatrix}, \quad diag(\mathbf{a}) = \begin{pmatrix} a_1 & & \\ & \ddots & \\ & & a_n \end{pmatrix}$$

استفاده می‌شوند. پهنهای باند ماتریس A به صورت $\max\{|i - j| : A_{ij} \neq 0\}$ تعریف می‌شود. به طور مشابه پهنهای باند پایینی A برابر با $\max\{|i - j| : A_{ij} \neq 0, i > j\}$ و پهنهای باند بالایی برابر نشانگر $\mathcal{I}_n = \{(i, j) : i = 1, \dots, n, j = 1, \dots, n\}$ است.

مشبکه^۲ (توری^۳) از اندازه^۴ $n = (n_1, n_2)$ است. برای $x_C = \{x_i : i \in C\}$ ، $C \subset \mathcal{I} = \{1, \dots, n\}$ است. تعریف می‌شود. اگر مجموعه $\mathcal{I} - C$ نشان داده شود، آنگاه $x_{-C} = \{x_i : i \in -C\}$ است. زیرا مجموعه $C_1 \setminus C_2 = \{i \in \mathcal{I} : i \notin C_2\} \in \mathcal{C}_\infty$ ، $i \in C_1 \setminus C_2 \in \mathcal{C}_\infty$ است.

بت سا روانش زیمم مقر ود اراد ت سا همچ رگلمع کی و برض رگلمع کی بل ماشه $b * x + a$ ت رایبع
هل اشم ن اوینه هب دوشی ه مدیمانز ^۴(روانش زیمم مقر ت رایبع کی به ساحمی اهرگلمع دادمه

Leading Principal Submatrix¹

Lattice^r

Grid^r

Floating Point Operation

۱.۲.۱ استقلال شرطی

برای $C \subset \mathcal{I}$ چگالی شرطی x_C به شرط x_{-C} عبارت است از

$$\pi(\mathbf{x}_C | \mathbf{x}_{-C}) = \frac{\pi(\mathbf{x}_C, \mathbf{x}_{-C})}{\pi(\mathbf{x}_{-C})} \propto \pi(\mathbf{x}). \quad (1.2.1)$$

دو متغیر تصادفی X و Y مستقل هستند، اگر و تنها اگر $\pi(x, y) = \pi(x)\pi(y)$ و با نماد $X \perp Y$ نمایش داده شوند. دو متغیر تصادفی X و Y برای Z داده شده مستقل شرطی نامیده می‌شوند، اگر و تنها اگر $\pi(x, y | z) = \pi(x|z)\pi(y|z)$ و با نماد $X \perp Y | Z$ نمایش داده می‌شود.

قضیه ۱.۲.۱ (رو و هلد، ۲۰۰۵):

$$x \perp y | z \Leftrightarrow \pi(x, y, z) = f(x, z)g(y, z) \quad (2.2.1)$$

برای بعضی توابع f و g ، و همهٔ z -هایی که $0 > \pi(z)$ است.

۲.۲.۱ گراف

گراف مجموعه‌ای از رأس‌ها است که تعدادی یال به هم وصل شده‌اند. گراف^۵ به صورت زوج مرتب $(\mathcal{V}, \mathcal{E})$ نشان داده می‌شود، که در آن \mathcal{V} مجموعه‌ای متناهی و غیرتنهی از راس‌ها و \mathcal{E} زیرمجموعهٔ تمام زوج‌های نامرتب از عناصر نامساوی \mathcal{V} به صورت

$$\mathcal{E} \subseteq \{\{i, j\} : i, j \in \mathcal{V}, i \neq j\}$$

است. اعضای \mathcal{V} را رأس‌های گراف \mathcal{G} و اعضای \mathcal{E} را یال‌های آن می‌نامند. بین دو رأس یک گراف ساده^۶ حداقل یک یال وجود دارد.

⁵ Graph

⁶ Simple Graph

اگر \mathcal{E} زیرمجموعه‌ای از تمام زوج‌های مرتب عناصر \mathcal{V} باشد، یعنی

$$\mathcal{E} \subseteq \{(i, j) : i, j \in \mathcal{V}, i \neq j\}$$

آن‌گاه \mathcal{G} گراف سودار^۷ نامیده می‌شود.

گراف \mathcal{G} کامل نامیده می‌شود هرگاه بین هر دو رأس آن دقیقاً یک یال وجود داشته باشد. در ادامه فرض می‌شود که $\mathcal{V} = \{1, \dots, n\}$ است، در این موارد گراف را نشان‌دار^۸ گویند. شکل ۱.۲.۱ یک گراف ساده شامل سه رأس و دو یال را نشان می‌دهد.



شکل ۱.۲.۱: نمایی از یک گراف ساده

همسایه‌های^۹ رأس i ، رأس‌هایی در گراف \mathcal{G} هستند که یالی مشترک با آن دارند، به بیان دیگر

$$ne(i) = \{j \in \mathcal{V} : \{i, j\} \in \mathcal{E}\}.$$

به طور مشابه برای مجموعه $A \subset \mathcal{V}$ ، همسایه‌های A به صورت

$$ne(A) = \bigcup_{i \in A} ne(i) \setminus A$$

تعریف می‌شود و شامل همه رأس‌هایی است که در A نیستند اما همسایگی با رأس‌های موجود در A دارند. یک مسیر از رأس i_1 به رأس i_m دنباله‌ای مجرزا از رئوس داخل \mathcal{V} به صورت $i_1 \dots i_m$ است که

directed graph^۷

Labelled^۸

Neighbors^۹

به ازای هر $j = 1, \dots, m - 1$ ، زوج مرتب (i_j, i_{j+1}) در \mathcal{E} باشد.

زیرمجموعه $C \subset \mathcal{V}$ جدا کننده دو رأس $i \notin C$ و $j \notin C$ است، اگر هر مسیر از i به j شامل حداقل یک رأس از C باشد. دو مجموعه مجزای $B \subset \mathcal{V} \setminus C$ و $A \subset \mathcal{V} \setminus C$ به وسیله C جدا شده هستند، اگر هر $i \in A$ و $j \in B$ به وسیله C جدا شده باشند، یعنی نمی‌توان روی گراف از A به سمت B قدم زد بدون این که از C عبور کرد.

وقتی دو رأس i و j همسایه‌هایی در گراف \mathcal{G} باشند، با نماد \mathcal{G}_{ij} نشان داده می‌شود. بدیهی است که \mathcal{G}_{ij} اگر و تنها اگر \mathcal{G}_{ji} .

اگر A زیرمجموعه‌ای از \mathcal{V} باشد، گراف حاصل بعد از حذف همه رأس‌هایی که در A نیستند و همه یال‌هایی که حداقل یک رأس آن‌ها در A قرار دارند را گراف محدود شده به A نامند و یا ابا نمایش داده می‌شود، که در آن $\mathcal{G}^A = \{\mathcal{V}^A, \mathcal{E}^A\}$

$$\mathcal{V}^A = A, \quad \mathcal{E}^A = \{\{i, j\} \in \mathcal{E}, \{i, j\} \in A \times A\}.$$

است.

مثال ۱.۲.۱ اگر گراف شکل ۱.۲.۱ و $\{1, 2\}$ باشد، آن‌گاه گراف محدود به A عبارت است از $\mathcal{G}^A = \{1, 2\}$ که در آن $\mathcal{V}^A = \{1, 2\}$ و $\mathcal{E}^A = \{\{1, 2\}\}$ است.

۳.۲.۱ ماتریس همیشه مثبت متقارن

ماتریس $A_{n \times n}$ همیشه مثبت است اگر و تنها اگر برای هر بردار $\mathbf{x} \neq \mathbf{0}$ ، $\mathbf{x}^T A \mathbf{x} > 0$ باشد. اگر A متقارن نیز باشد به آن ماتریس همیشه مثبت متقارن^{۱۰} (SPD) گویند. ماتریس $n \times n$ ، نیمه

Symmetric Positive Definite^{۱۰}

مثبت^{۱۱} نامیده می‌شود، اگر و تنها اگر

$$\mathbf{x}^T \mathbf{A} \mathbf{x} \geq 0, \quad \forall \mathbf{x} \neq \mathbf{0}.$$

و با نماد $\mathbf{A} \geq 0$ نشان داده می‌شود. همچنین اگر \mathbf{A} متقارن باشد به آن ماتریس نیمه‌مثبت متقارن (SPSD) گویند.

برخی از خواص ماتریس‌های SPD عبارتند از

$$\text{rank}(\mathbf{A}) = n \quad (1)$$

$$|\mathbf{A}| > 0 \quad (2)$$

$$A_{ii} > 0 \quad (3)$$

$$A_{ii} - A_{jj} - A_{ij}^T > 0, \quad i \neq j \quad (4)$$

$$A_{ii} - A_{jj} - 2|A_{ij}| > 0, \quad i \neq j \quad (5)$$

$$\max A_{ii} > \max_{i \neq j} |A_{ij}| \quad (6)$$

$$\mathbf{A}^{-1} \text{ ماتریس SPD است.} \quad (7)$$

(۸) همه زیرماتریس‌های اصلی \mathbf{A} نیز SPD هستند.

(۹) اگر \mathbf{A} و \mathbf{B} هر دو ماتریس SPD باشند، $\mathbf{A} + \mathbf{B}$ نیز SPD خواهد بود، اما عکس آن لزوماً برقرار نیست.

(۱۰) اگر \mathbf{A} و \mathbf{B} هر دو ماتریس SPD باشند، آن گاه $\mathbf{AB} = \mathbf{BA}$ نیز یک ماتریس SPD است.

Positive Semidefinite^{۱۱}

۱۱) شرایط لازم و کافی برای این که ماتریس A ، SPD باشد عبارتند از:

الف) همه مقادیر ویژه A اکیداً^{۱۰} مثبت هستند.

ب) ماتریسی مانند C وجود دارد که $A = CC^T$ است.

ج) همه زیرماتریس‌های اصلی مقدم، دارای دترمینان اکیداً^{۱۱} مثبت هستند.

۳.۱ میدان تصادفی مارکوفی گاووسی

فرض کنید بردار تصادفی $x = (x_1, \dots, x_n)^T$ دارای توزیع چندمتغیره نرمال با میانگین μ و ماتریس کواریانس Σ باشد. به علاوه $(\mathcal{V}, \mathcal{E}) = \mathcal{G}$ گرافی نشان‌دار باشد، که در آن \mathcal{E} شامل همه زوج‌های $\{i, j\}$ است که راس‌های i و j همیچ یال مشترکی نداشته باشند، اگر و تنها اگر $x_j | x_{-ij} \perp x_i$. در این صورت x یک میدان تصادفی مارکوفی گاووسی^{۱۲} (GMRF) نسبت به گراف \mathcal{G} نامیده می‌شود.

قبل از بیان یک تعریف رسمی برای GMRF، ارتباط بین گراف G و پارامترهای توزیع نرمال بیان می‌شود. از آنجا که μ تاثیری بر استقلال شرطی دوبه‌دوی درایه‌های x ندارد، می‌توان استنباط کرد که این اطلاعات تنها در ماتریس کواریانس Σ پنهان شده است، بنابراین ماتریس دقت، که به صورت $\Sigma^{-1} = Q$ تعریف می‌شود، نقش مهمی را در تحلیل GMRF ایفا می‌کند.

قضیه ۱.۳.۱ (رو و هلد، ۲۰۰۵): اگر x دارای توزیع نرمال چندمتغیره با میانگین μ و ماتریس دقت $Q > 0$ باشد، آن‌گاه درایه z_{ij} ام ماتریس Q ، یعنی Q_{ij} برابر صفر است اگر و تنها اگر

$$x_i \perp x_j \mid x_{-ij}$$

Gaussian Markov Random Fields^{۱۲}

با توجه به قضیه ۱.۳.۱ درایه‌های غیر صفر ماتریس Q گراف \mathcal{G} را مشخص می‌کند و براساس آن‌ها می‌توان استقلال شرطی x_i و x_j را بررسی نمود.

تعریف ۱.۳.۱ میدان تصادفی مارکوفی گاووسی: بردار تصادفی $\mathbf{x} = (x_1, \dots, x_n)^T \in R^n$ یک GMRF، تحت گراف نشان دار $(\mathcal{V}, \mathcal{E}) = \mathcal{G}$ با میانگین μ و ماتریس دقت $Q > \mathbf{0}$ است، اگر و تنها اگر تابع چگالی آن به صورت

$$\pi(\mathbf{x}) = (2\pi)^{-\frac{n}{2}} |Q|^{\frac{1}{2}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \mu)^T Q (\mathbf{x} - \mu)\right\} \quad (3.3.1)$$

باشد و برای هر $i \neq j \in \mathcal{E}$

$$Q_{ij} \neq 0 \iff \{i, j\} \in \mathcal{E}.$$

اگر Q یک ماتریس چگال باشد، یعنی تُنک نباشد، گراف \mathcal{G} همبند کامل^{۱۳} نامیده می‌شود و نشان دهنده‌آن است که هر توزیع نرمال با ماتریس دقت GMRF یک SPD است و هر GMRF دارای توزیع نرمال با ماتریس دقت SPD است.

قضیه ۲.۳.۱ (رو و هلد، ۲۰۰۵): فرض کنید x یک GMRF تحت گراف $(\mathcal{V}, \mathcal{E}) = \mathcal{G}$ با میانگین μ و ماتریس دقت $Q > \mathbf{0}$ باشد، آن‌گاه میانگین، دقت و همبستگی شرطی به ترتیب عبارتند از

$$E(x_i | \mathbf{x}_{-i}) = \mu_i - \frac{1}{Q_{ii}} \sum_{j:j \sim i} Q_{ij}(x_j - \mu_j) \quad (4.3.1)$$

$$Prec(x_i | \mathbf{x}_{-i}) = Q_{ii} \quad (5.3.1)$$

$$Corr(x_i, x_j | \mathbf{x}_{-ij}) = -\frac{Q_{ij}}{\sqrt{Q_{ii}Q_{jj}}}, \quad i \neq j. \quad (6.3.1)$$

درایه‌های قطری ماتریس Q دقت‌های شرطی x_i به شرط x_{-i} و مولفه‌های خارج از قطر اطلاعاتی در مورد همبستگی شرطی بین x_i و x_j به شرط x_{-ij} ارائه می‌کنند. اما از آن‌جا که درایه‌های ماتریس کواریانس $(\Sigma_{ij}) = \Sigma$ ، واریانس $Var(x_i) = \Sigma_{ii}$ و همبستگی $Corr(x_i, x_j) = \Sigma_{ij} / \sqrt{(\Sigma_{ii}\Sigma_{jj})}$ کناری x_i و همبستگی کناری بین x_i و x_j در اختیار قرار می‌دهد. تفسیر کناری با Σ مستقیماً حاوی اطلاعات مفیدی است و می‌توان از آن برای بیان توزیع‌های کناری یک یا دو بعدی متغیره استفاده کرد، در حالی که در مورد Q این کار دشوار است و باید از توزیع توأم روی x_{-i} یا x_{-ij} انتگرال گرفت، زیرا با توجه به تعریف $\Sigma = Q^{-1}$ ، در حالت کلی Σ_{ii} به همه مولفه‌های Q مرتبط است.

۱.۳.۱ خواص مارکوفی GMRF

گراف \mathcal{G} با بررسی وجود یا عدم وجود استقلال شرطی $x_{-ij} \perp x_i | x_{-i}$ تعریف شد، که با توجه به قضیه ۱.۳.۱ معادل با صفر یا غیر صفر بودن درایه‌های غیرقطری Q_{ij} است. از این رو گراف \mathcal{G} از مولفه‌های غیر صفر Q ساخته می‌شود. بنابراین از ویژگی‌های قابل توجه و مفید GMRF این است که اطلاعات زیادی در مورد استقلال شرطی از گراف \mathcal{G} قابل استنتاج است. ویژگی‌های مارکوفی موضعی^{۱۴}، مارکوفی فراموضعی^{۱۵} و مارکوفی دوبعدی^{۱۶} که برای تعریف گراف به کار می‌رود، برای GMRF‌ها هم ارزند.

Local^{۱۴}Global^{۱۵}Pairwise^{۱۶}

قضیه ۳.۳.۱ فرض کنید x یک GMRF تحت گراف $(\mathcal{V}, \mathcal{E}) = \mathcal{G}$ باشد. آن‌گاه جملات زیر هم‌ارزند.

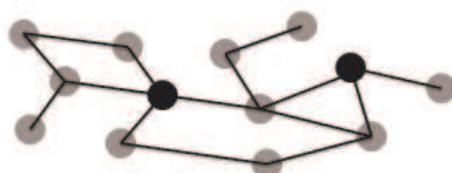
الف) ویژگی مارکوفی دوبه‌دو: اگر $\mathcal{E} \notin \{i, j\}$ و $j \neq i$ آن‌گاه $.x_i \perp x_j | \mathbf{x}_{-ij}$

ب) ویژگی مارکوفی موضعی: برای هر $i \in \mathcal{V}$ ، $.x_i \perp \mathbf{x}_{-\{i, ne(i)\}} | \mathbf{x}_{ne(i)}$

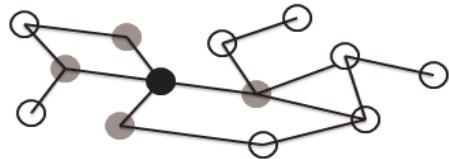
ج) ویژگی مارکوفی فراموضعی: اگر A ، B و C مجموعه‌های مجزا و مجموعه‌ای ناتهی باشد که A و B را از هم جدا می‌کند، آن‌گاه

$$\mathbf{x}_A \perp \mathbf{x}_B | \mathbf{x}_C. \quad (7.3.1)$$

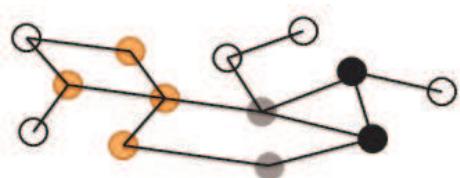
در شکل ۲.۳.۱ دو رأس مشکی به شرط معلوم بودن رأس‌های توسي از هم مستقل هستند. در شکل ۳.۳.۱ رأس مشکی از رأس‌های سفید به شرط معلوم بودن رأس‌های توسي مستقل است. در شکل ۴.۳.۱ رأس‌های مشکی و توسي به شرط معلوم بودن رأس‌های هاشور از هم مستقل هستند. شکل‌های ۲.۳.۱، ۳.۳.۱ و ۴.۳.۱ قضیه ۲.۳.۱ و ۳.۳.۱ را شرح می‌دهد.



شکل ۲.۳.۱: ویژگی مارکوفی دوبه‌دو



شکل ۳.۱: ویژگی مارکوفی موضعی



شکل ۴.۱: ویژگی مارکوفی فراموضعی

۲.۳.۱ ویژگی‌های شرطی میدان تصادفی مارکوفی گاووسی

بای بررسی ویژگی‌های شرطی GMRF، پارامتریدن کانونی که روشی دیگر برای نمایش توزیع نرمال است مفید خواهد بود. توزیع شرطی $x_A | x_B$ به شرط x_B ، که در آن $B = -A$ و A دو مجموعه ناتهی هستند را درنظر بگیرید. در این صورت میانگین و ماتریس دقت بردار $x = \begin{pmatrix} x_A \\ x_B \end{pmatrix}$ به صورت زیر افزایش شوند:

$$\mu = \begin{pmatrix} \mu_A \\ \mu_B \end{pmatrix}, \quad \text{و} \quad Q = \begin{pmatrix} Q_{AA} & Q_{AB} \\ Q_{BA} & Q_{BB} \end{pmatrix}. \quad (4.3.1)$$

قضیه ۴.۳.۱ (رو و هلد، ۲۰۰۵): فرض کنید x یک GMRF تحت گراف $(\mathcal{V}, \mathcal{E})$ با میانگین μ و ماتریس دقت $Q > \mathbf{0}$ باشد. برای دو مجموعه غیرتنهی $A \subset \mathcal{V}$ و $B = \mathcal{V} \setminus A$ ، توزیع شرطی $x_A | x_B$

یک GMRF تحت گراف \mathcal{G}^A با میانگین $\mu_{A|B}$ و ماتریس دقت $Q_{A|B} > \mathbf{0}$ است، که در آن

$$\begin{aligned}\mu_{A|B} &= \mu_A - Q_{AA}^{-1} Q_{AB} (\mathbf{x}_B - \mu_B) \\ Q_{AB} &= Q_{AA}.\end{aligned}\quad (9.3.1)$$

قضیه ۲.۳.۱ که تعمیم قضیه ۲.۳.۱ است، نتایج مفیدی را به دست می‌دهد. اول این‌که $Q_{A|B}$ و در واقع Q_{AA} در دسترس است و نیاز به محاسبه ماتریس دقت شرطی نیست و گراف \mathcal{G}^A تنها با حذف راس‌هایی که در A نیستند و یال‌های متناظر آن‌ها به دست می‌آید. دوم این‌که، چون Q_{ij} صفر است مگر این‌که $i \in ne(j)$ باشد، میانگین شرطی تنها به مقدار μ و Q در $A \cup ne(A)$ وابسته است. بنابراین برای محاسبه میانگین شرطی $\mu_{A|B}$ فقط نیاز به حل دستگاه خطی

$$Q_{AA}(\mu_{A|B} - \mu_A) = -Q_{AB}(\mathbf{x}_B - \mu_B)$$

است، ولزوماً نیاز به معکوس کردن Q_{AA} نیست.

تعريف ۲.۳.۱ (پارامتریدن کانونی): یک GMRF تحت گراف \mathcal{G} باتابع چگالی

$$\pi(\mathbf{x}) \propto \exp\left(-\frac{1}{2} \mathbf{x}^T Q \mathbf{x} + \mathbf{b}^T \mathbf{x}\right),$$

فرم کانونی با پارامترهای کانونی \mathbf{b} و $Q > \mathbf{0}$ نامیده می‌شود. این فرم دارای ماتریس دقت Q و میانگین $\mathbf{b} = Q^{-1}\mu$ است و با نماد $x \sim N_C(\mathbf{b}, Q)$ نشان داده می‌شود. رابطه پارامتریدن کانونی با توزیع نرمال به صورت $N(\mu, Q^{-1}) = N_C(Q\mu, Q)$ است.

۲.۳.۱ مشخص‌سازی GMRF با شرطی‌های کامل

شیوه دیگر مشخص کردن یک GMRF با میانگین و ماتریس دقت، استفاده از شرطی‌های کامل است. بسیج (۱۹۷۵) در این شیوه پیشگام است و این مدل‌ها را با نام اتو رگرسیو $\{\pi(x_i | \mathbf{x}_{-i})\}$

شرطی^{۱۷} (CAR) معرفی کرد. در ادامه خصوصیاتی که باید روی شرطی‌های کامل تحمیل شود تا یک GMRF معتبر باشد، بیان می‌شود.

فرض کنید شرطی‌های کامل، توزیع نرمال با میانگین‌ها و دقت‌های شرطی به ترتیب به صورت

$$E(x_i | \mathbf{x}_{-i}) = \mu_i - \sum_{j:j \sim i} \beta_{ij} (x_j - \mu_j) \quad i = 1, \dots, n \quad (10.3.1)$$

$$Prec(x_i | \mathbf{x}_{-i}) = \kappa_i > 0 \quad (11.3.1)$$

برای بعضی $\{\beta_{ij}, i \neq j\}$ و بردارهای μ و κ باشند. با مقایسه عبارات (۴.۳.۱) و (۱۰.۳.۱)، اگر درایه‌های ماتریس Q به صورت

$$Q_{ii} = \kappa_i, \quad \text{و} \quad Q_{ij} = \kappa_i \beta_{ij}$$

انتخاب شوند و ماتریس Q متقارن باشد، یعنی $\kappa_i \beta_{ij} = \kappa_j \beta_{ji}$ آن‌گاه چگالی x موجود و بنابر قضیه بعد منحصر به‌فرد است.

قضیه ۵.۳.۱ (رو و هل McD، ۲۰۰۵): فرض کنید n توزیع شرطی کامل نرمال با میانگین‌ها و دقت‌های شرطی (۱۰.۳.۱) و (۱۱.۳.۱) داده شده باشند. آن‌گاه x یک GMRF تحت گراف نشاندار

با میانگین μ و ماتریس دقت $Q = (Q_{ij})$ با درایه‌های

$$Q_{ij} = \begin{cases} \kappa_i \beta_{ij} & i \neq j \\ \kappa_i & i = j \end{cases}$$

است، به طوری که $\kappa_i \beta_{ij} = \kappa_j \beta_{ji}$, $i \neq j$ و $\mathbf{Q} > \mathbf{0}$.

Conditional Autoregression^{۱۸}

۴.۳.۱ میدان تصادفی مارکوفی گاوی چندمتغیره

فرض کنید x یک GMRF نسبت به گراف \mathcal{G} است. ویژگی مارکوفی بر

$$\pi(x_i | \mathbf{x}_{-i}) = \pi(x_i | \{x_j : j \sim i\})$$

دلالت دارد، که در آن x_i مقدار متناظر با رأس i است. اغلب رأس‌ها دارای تعبیر فیزیکی مانند رأس‌های یک مشبكه یا عنصرهای تصویری^{۱۸} یک منطقه برنقشه یک کشور هستند که ممکن است برای تعریف همسایگی رأس i استفاده شوند. برای تعمیم این مسئله، از به هم پیوستن بردارهای p -بعدی، \mathbf{x}_i ، ($i = 1, \dots, n$) برای هر یک از n رأس یک GMRF چندمتغیره با اندازه np به صورت $\mathbf{x} = (\mathbf{x}_1^T, \dots, \mathbf{x}_n^T)^T$ حاصل می‌شود. ویژگی مارکوفی در هر رأس محفوظ است، یعنی $\pi(x_i | \mathbf{x}_{-i}) = \pi(x_i | \{x_j : j \sim i\})$ ، که در آن \sim نسبت به گراف یکسان \mathcal{G} است. فرض کنید $\tilde{\mathbf{Q}}_{ij}$ یک ماتریس $p \times p$ میانگین و $\mu = (\mu_1^T, \dots, \mu_n^T)^T$ دقت \mathbf{x} باشد. هر مولفه $\tilde{\mathbf{Q}}_{ij}$ ماتریس

است. با توجه به قضیه ۱.۳.۱ رابطه

$$\mathbf{x}_i \perp \mathbf{x}_j \mid \mathbf{x}_{-ij} \iff \tilde{\mathbf{Q}}_{ij} = \mathbf{0}$$

به دست می‌آید. یک GMRF-متغیره را می‌توان با بسط تعریف ۱.۳.۱ برای GMRF تعریف نمود.

تعریف ۴.۳.۱ (GMRF چندمتغیره): بردار تصادفی $\mathbf{x} = (\mathbf{x}_1^T, \dots, \mathbf{x}_n^T)^T$ ، که در آن $\dim(\mathbf{x}_i) = p$ است، یک GMRF-متغیره نسبت به گراف $(\mathcal{V} = \{1, \dots, n\}, \mathcal{E})$ با میانگین μ و ماتریس دقت $\tilde{\mathbf{Q}}$ نامیده می‌شود، اگر و تنها اگر چگالی آن به صورت

$$\pi(\mathbf{x}) = \left(\frac{1}{2\pi} \right)^{-\frac{np}{2}} |\tilde{\mathbf{Q}}|^{\frac{1}{2}} \exp \left(-\frac{1}{2} (\mathbf{x} - \mu)^T \tilde{\mathbf{Q}} (\mathbf{x} - \mu) \right)$$

^{۱۸}pixel

$$= (\frac{1}{\sqrt{\pi}})^{-\frac{np}{2}} |\tilde{Q}|^{\frac{1}{2}} \exp \left(-\frac{1}{2} \sum_{ij} (\mathbf{x}_i - \boldsymbol{\mu}_i)^T \tilde{Q}_{ij} (\mathbf{x}_j - \boldsymbol{\mu}_j) \right)$$

باشد و برای هر $i \neq j$

$$\tilde{Q}_{ij} \neq \mathbf{0} \iff \{i, j\} \in E.$$

همه نتایج به دست آمده برای GMRF قابل تعمیم برای p -متغیره است.

۴.۱ الگوریتم‌های محاسباتی و شبیه‌سازی GMRF

در این بخش الگوریتم‌هایی برای محاسبه لگاریتم چگالی، محاسبه چگالی‌های شرطی، شبیه‌سازی از GMRF و شبیه‌سازی شرطی روی زیرمجموعه‌ای از GMRF، قیدهای سخت یا قیدهای نرم و ارزیابی لگاریتم چگالی‌های شرطی متناظر ارائه می‌شود. همه موارد با عملکردهای ساده ماتریسی روی ماتریس دقت Q ، که ٹنک است فرمول‌بندی خواهند شد. به دلیل ٹنک بودن ماتریس دقت، ذخیره‌سازی آسان تر و محاسبات سریع‌تر صورت خواهد گرفت. به عنوان مثال، در تجزیه چولسکی $Q = L^T L$ ، ماتریس L پایین مثلثی است که می‌تواند ٹنک باشد و شامل درایه‌های غیر صفر ماتریس Q باشد.

در حالت کلی، مقدار flop برای محاسبه تجزیه چولسکی از مرتبه $\mathcal{O}(n^3)$ است، که در ماتریس‌های ٹنک به $\mathcal{O}(n)$ کاهش می‌یابد، این تعداد در الگوهای فضایی از مرتبه $\mathcal{O}(n^{3/2})$ و GMRF‌های فضایی زمانی $\mathcal{O}(n^2)$ است. به طور مشابه اگر L ، ماتریس ٹنک باشد، حل معادله $Lx = b$ سریع‌تر انجام می‌شود. قبل از بررسی روش‌های عددی برای ماتریس‌های ٹنک ابتدا به نحوه شبیه‌سازی و ارزیابی لگاریتم چگالی برای حالت کلی ماتریس Q ارائه می‌شود. فرض کنید $A_{n \times n}$ یک ماتریس متقارن همیشه مثبت باشد، بنابراین تنها یک مثلث چولسکی L وجود دارد که برای هر i ، $0 < L_{ii} < A$ است. تعداد flop برای محاسبه L برابر $n^{3/2}$ است. این تجزیه مبنایی

برای حل دستگاه‌های خطی مانند $Ax = b$ و $AX = B$ یا به طور معادل محاسبه $x = A^{-1}b$ است.

الگوریتم ۱.۴.۱ (حل معادله $Ax = b$):

۱) تجزیهٔ چولسکی $A = L^T L$ محاسبه شود.

۲) معادله $L\nu = b$ بر حسب ν حل شود.

۳) معادله $L^T x = \nu$ بر حسب x حل شود.

از آن جا که

$$x = (L^{-1})^T \nu = (L^{-1})^T (L^{-1}b) = (LL^T)^{-1}b = A^{-1}b$$

پس x پاسخ معادله $Ax = b$ است. در گام دوم الگوریتم ۱.۴.۱ برای محاسبه ν از یک حلقهٔ پیشرو به صورت

$$\nu_i = \frac{1}{L_{ii}}(b_i - \sum_{j=1}^{i-1} L_{ij}\nu_j), \quad i = 1, \dots, n$$

استفاده می‌شود، که جانشین‌سازی پیشرو^{۱۹} نامیده می‌شود. به طور مشابه گام سوم نیز جانشین‌سازی پیشرو^{۲۰} نامیده می‌شود که در آن x از یک حلقهٔ پیشرو به صورت

$$x_i = \frac{1}{L_{ii}}(\nu_i - \sum_{j=i+1}^n L_{ji}x_j), \quad i = n, \dots, 1 \quad (12.4.1)$$

محاسبه می‌شود. تعداد کل flop‌های الگوریتم ۱.۴.۱ برابر n^2 است.

Forward Substitution^{۱۹}

Backward Substitution^{۲۰}