

# فصل اول

مقدمه‌ای بر بهینه‌سازی غیر خطی

## ۱- مقدمه

امروزه مفهوم «بهینه‌سازی» به عنوان یک اصل زیر بنایی در تحلیل بسیاری از مسائل پیچیده تصمیم‌گیری یا تخصیص کاملاً پذیرفته شده است. برای استفاده از آن ما باید در ابتدا هدف را تعیین کنیم. این هدف می‌تواند سود، زمان، انرژی پتانسیل و به طور کلی هر مقدار یا مجموعه‌ای از مقادارها باشد که می‌تواند توسط تعدادی از متغیرها نمایش داده شود. از اینرو، هدف ما یافتن مقدار متغیرهایی است که هدف را بهینه کند. فرایند تعیین هدف، متغیرها و محدودیت‌ها برای یک مسئله داده شده به «مدل سازی» معروف است. ساخت یک مدل مناسب اولین گام، و گاهی اوقات مهم‌ترین گام، در فرایند بهینه‌سازی است.

پس از اینکه مدل فرمول‌بندی شد، یک الگوریتم بهینه‌سازی می‌تواند برای یافتن جواب آن مورد استفاده قرار گیرد. متأسفانه هیچ الگوریتم بهینه‌سازی جامعی وجود ندارد، بلکه الگوریتم‌های بی‌شماری وجود دارند که هر کدام از آن‌ها برای نوع خاصی از مسئله بهینه‌سازی مناسب هستند. تعیین یک الگوریتم مناسب، انتخاب مهمی است، چرا که تعیین می‌کند مسئله به سرعت یا به کندی حل می‌شود و به علاوه آیا مسئله جواب خواهد داشت یا خیر. پس از آنکه یک الگوریتم بهینه‌سازی برای مدل به کار گرفته شد، باید بتوانیم تشخیص دهیم که آیا الگوریتم مورد نظر در یافتن جواب بهینه موفق خواهد شد یا خیر. در بسیاری از حالات، برای پاسخ دادن به اینکه آیا مجموعه جواب جاری واقعاً جواب مسئله است یا خیر، شرایطی به عنوان شرایط بهینگی وجود دارد. به بیان ساده ریاضی، یک مسئله بهینه‌سازی، یافتن مینیمم یا ماکسیمم مقدار یک تابع به همراه تعدادی محدودیت می‌باشد.

کاربردهای بهینه‌سازی در علوم پایه، مهندسی، اقتصاد و تجارت بسیار فراوان است. به طوریکه گفته می‌شود ما در عصر بهینه‌سازی زندگی می‌کنیم. به عنوان مثال می‌توان به طراحی راکتورهای شیمیایی، طراحی مهندسی هوا فضا، تخصیص منابع، زمان بندی، طراحی و ساخت پل‌ها و ساختمان‌ها و... اشاره کرد. بهینه‌سازی در شاخه آنالیز عددی نیز کاربردهایی نظیر اصول نوسانی در  $PDE$ ، معادلات غیر خطی در  $ODE$  و توابع جریمه‌ای دارد. در ادامه به بررسی انواع مسائل بهینه‌سازی می‌پردازیم.

## ۱-۲ انواع مسائل بهینه‌سازی

فرم عمومی یک مسئله بهینه‌سازی غیرخطی به صورت زیر است:

$$\begin{aligned} \min & f(x) \\ \text{s.t.} & \\ & h_i(x) = 0, \quad i \in I = \{1, \dots, n\} \\ & g_j(x) \leq 0, \quad j \in J = \{1, \dots, m\} \end{aligned} \quad (1.2.1)$$

$$x \in C$$

که در آن  $C \subseteq R^n$  یک مجموعه داده شده و  $f$  و  $h_1, \dots, h_n$  و  $g_1, \dots, g_m$  توابع تعریف شده روی  $C$  (یا یک مجموعه باز شامل  $C$ ) هستند.

تابع  $f(x)$  تابع هدف و معادله‌های  $h_i(x) = 0$  و نامعادله‌های  $g_i(x) \leq 0$  محدودیت‌ها یا قيود مسئله نامیده می‌شوند. مجموعه جواب‌های شدنی مسئله فوق با

$$F = \{x \in C \mid h_i(x) = 0, \quad i = 1, \dots, n, \quad g_j(x) \leq 0, \quad j = 1, \dots, m\}$$

نمایش داده می‌شود.

- اگر  $F = \emptyset$  مسئله را نشدنی گوئیم.
- اگر  $f$  روی  $F$  از پایین کراندار نباشد، آنگاه مسئله بی‌کران نامیده می‌شود.
- اگر مقدار مینیمم  $f$  روی  $F$  در  $x^* \in F$  به دست آورده شود آنگاه  $x^*$  یک جواب بهینه و  $f(x^*)$  مقدار بهینه نامیده می‌شود.

**تعریف ۱-۲-۱:** تابع  $f: R^n \rightarrow R$  را مجذوری گوئیم هرگاه

$$\exists Q \in R^{n \times n}, C \in R^n, d \in R \quad \text{s.t.} \quad f(x) = \frac{1}{2}x^T Qx + C^T x + d$$

در حالت خاص که  $Q = 0$  تابع را آفین و اگر  $Q = 0$  و  $d = 0$  تابع را خطی گویند.

مسئله بهینه‌سازی عمومی (۱.۲.۱)، با توجه به طبیعت تابع هدف و محدودیت‌های آن (از نظر خطی، غیرخطی و محدب بودن) و همچنین از نظر تعداد متغیرها و هموار بودن توابع موجود (مشتق پذیری یا عدم آن)، می‌تواند به کلاس‌های مختلفی طبقه بندی شود. در حالت کلی مسائل بهینه‌سازی غیرخطی در دو کلاس مهم زیر مورد بررسی قرار می‌گیرند.

(۱) بهینه‌سازی نامقید.

(۲) بهینه‌سازی مقید.

هدف این پایان‌نامه، ارائه الگوریتم‌هایی برای حل مسائل بهینه‌سازی غیرخطی نامقید می‌باشد. قابل توجه

اینکه در الگوریتم‌های موجود برای حل مسائل بهینه‌سازی مقید نیز معمولاً نیاز به حل چندین مسئله بهینه‌سازی غیرخطی نامقید می‌باشد که این امر، اهمیت موضوع فوق را بیشتر نمایان می‌سازد.

### ۱-۳ الگوریتم‌های بهینه‌سازی

اغلب الگوریتم‌هایی که برای حل مسائل بزرگ بهینه‌سازی طراحی شده‌اند، از نوع تکراری هستند. در روند جستجو برای یافتن نقطه‌ای که مسئله بهینه‌سازی را حل کند، معمولاً یک نقطه اولیه  $x_0$  انتخاب می‌شود، سپس در یک فرایند تکراری به دنبال امکان بهبود جواب در هر مرحله هستیم. با ادامه این روند، دنباله‌ای متوالی از نقاط به دست می‌آید که به یک نقطه جواب نزدیک می‌شود. برای مسائل بهینه‌سازی خطی، دنباله تولید شده متناهی است و الگوریتم پس از تعدادی متناهی مرحله (گرچه این تعداد در آغاز و دقیقاً مشخص نیست) به نقطه جواب می‌رسد. برای مسائل بهینه‌سازی غیرخطی، این دنباله در حالت کلی به یک نقطه جواب نمی‌رسد، اما به آن همگرا می‌شود. بنابراین در عمل هنگامی که نقطه‌ای به اندازه کافی نزدیک به نقطه جواب تولید گردد، این فرایند متوقف می‌شود.

یک الگوریتم مناسب باید حداقل دارای شرایط زیر باشد.

۱. حتی با وجود تولید خطا در حین اجرا، توانایی محاسبه جواب را داشته‌باشد.
۲. الگوریتم بیش از اندازه به زمان محاسبه یا ذخیره‌سازی نیاز نداشته‌باشد.
۳. الگوریتم تا حد امکان بدون تاثیر پذیری از خطای داده‌ها و خطای گرد کردن، توانایی یافتن جواب دقیق را داشته‌باشد.

این اهداف می‌توانند ناسازگار باشند. یک الگوریتم ممکن است برای کاهش خطا به مقدار قابل قبول، نیاز به زمان محاسبه بسیار زیادی داشته‌باشد. موضوعاتی مانند مرتبه همگرایی، نیازهای ذخیره‌سازی، سرعت و عوامل دیگر، موضوعات اساسی در بهینه‌سازی هستند، که ارزیابی کمی و مقایسه الگوریتم‌های مختلف را امکان‌پذیر می‌سازند.

عموماً الگوریتم‌هایی که برای حل مسائل بهینه‌سازی نامقید ارائه می‌شوند، الگوریتم‌های تکراری می‌باشند که یک دنباله  $\{x_k\}$  همگرا به جواب را می‌سازند. بنابراین در ادامه بحث به تعریف مرتبه همگرایی دنباله که رابطه مستقیمی با سرعت همگرایی دارد می‌پردازیم.

**تعریف ۱-۳-۱:** [۱] فرض کنید  $\{x_k\}_{k=1}^{\infty}$  دنباله‌ای در  $R^n$  و همگرا به  $x^*$  باشد. مرتبه همگرایی این دنباله را  $p^*$  گوییم هرگاه:

$$p^* = \sup \left\{ p: \limsup \frac{\|x_{k+1} - x^*\|}{\|x_k - x^*\|^p} < \infty \right\}.$$

هرچه  $p^*$  بزرگتر باشد، همگرایی سریعتر است. با معرفی  $\beta = \limsup \frac{\|x_{k+1} - x^*\|}{\|x_k - x^*\|^{p^*}}$  می‌توانیم تعاریف زیر را در مورد مرتبه همگرایی دنباله  $\{x_k\}_{k=1}^{\infty}$  ارائه دهیم.

- (a) هرگاه  $p^* = 1$  و  $0 < \beta < 1$  آنگاه همگرایی را خطی گوئیم.
- (b) هرگاه  $p^* = 1$  و  $\beta = 0$  آنگاه همگرایی را زیرخطی<sup>۱</sup> گوئیم.
- (c) هرگاه  $p^* = 1$  و  $\beta = 1$  آنگاه همگرایی را زیرخطی<sup>۲</sup> گوئیم.
- (d) هرگاه  $p^* = 2$  آنگاه همگرایی را مجذوری گوئیم.

اولین سوالی که در مسائل بهینه‌سازی مطرح می‌شود در مورد وجود جواب مسئله (۱.۴.۱) است. حکم مهمی که برای پاسخ دادن به این پرسش می‌توان از آن استفاده کرد قضیه ویراشتراس است. در قرن نوزدهم، کارل ویراشتراس (۱۸۹۷-۱۸۱۵) نتیجه مشهوری را در تحلیل ثابت کرد که یک تابع پیوسته حقیقی مقدار اینفیمم یا سوپریمم خود را روی یک مجموعه فشرده اختیار می‌کند. یعنی هر مسئله تصمیم‌گیری  $NLO^2$  همراه با شرط پیوستگی  $f$  و فشرده بودن ناحیه شدنی دارای جواب بهینه است. در ادامه به تعیین شرایط نقطه بهینه می‌پردازیم.

### ۱-۴ شرایط بهینگی برای مسئله بهینه‌سازی غیرخطی نامقید

مسئله زیر را در نظر بگیرید

$$\min f(x) \quad (1.4.1)$$

$$x \in R^n,$$

که در آن  $x \in R^n$  یک بردار حقیقی با  $n \geq 1$  مؤلفه می‌باشد و  $f$  یک تابع با مشتقات مرتبه دوم پیوسته است. برای یافتن جواب بهینه مسئله فوق ابتدا باید با خصوصیات جواب آن آشنا شویم. در این جهت به تعاریف زیر نیاز داریم. [۲]

**تعریف ۱-۴-۱ (گرادیان تابع):** فرض کنید تابع  $f: R^n \rightarrow R$ ، به‌طور پیوسته مشتق پذیر باشد. در هر نقطه  $x \in R^n$  یک بردار شامل مشتقات جزئی مرتبه اول  $f$  وجود دارد که بردار گرادیان نامیده می‌شود و به

---

1-Superlinear Convergence  
2-Sublinear Convergence  
3-Nonlinear programming optimization

صورت زیر تعریف می‌گردد.

$$g(x) = \nabla f(x) = \left( \frac{\partial f}{\partial x_1}(x), \dots, \frac{\partial f}{\partial x_n}(x) \right)^T. \quad (۲.۴.۱)$$

**تعریف ۱-۴-۲ (ماتریس هسی تابع):** فرض کنید تابع  $f: R^n \rightarrow R$  در هر  $x \in R^n$  دو بار به‌طور پیوسته مشتق‌پذیر باشد آنگاه یک ماتریس از مشتقات جزئی مرتبه دوم تابع  $f$  موجود است که ماتریس هسی نامیده می‌شود و آنرا به‌صورت  $\nabla^2 f(x)$  نمایش می‌دهیم. این ماتریس یک ماتریس مربعی متقارن است که درایه

$$(i, j) \text{ آن به صورت } \frac{\partial^2 f}{\partial x_i \partial x_j}(x) \text{ تعریف می‌شود. از آنجا که } j \text{ امین ستون این ماتریس عبارت است از}$$

$$\nabla \left( \frac{\partial f}{\partial x_j} \right)(x) \text{ از اینرو این ماتریس می‌تواند به صورت } \nabla(\nabla f(x))^T \text{ نوشته شود.}$$

در ابتدا مینیمم موضعی و سراسری تابع هدف مسئله (۱.۴.۱) را تعریف می‌کنیم.

**تعریف ۱-۴-۳ [۲]:** فرض کنید تابع  $f: R^n \rightarrow R$  داده شده باشد.

(۱) نقطه  $x^* \in R^n$  را مینیمم موضعی تابع  $f$  گوئیم، هرگاه

$$\exists \varepsilon > 0 \text{ s.t. } \forall x \in R^n : \text{if } \|x^* - x\| \leq \varepsilon \Rightarrow f(x^*) \leq f(x).$$

نقطه  $x^* \in R^n$  را مینیمم سراسری تابع  $f$  گوئیم، هرگاه به ازای هر  $x \in R^n$

$$f(x^*) \leq f(x).$$

(۲) نقطه  $x^* \in R^n$  را مینیمم موضعی اکید تابع  $f$  گوئیم، هرگاه

$$\exists \varepsilon > 0 \text{ s.t. } \forall x \in R^n : \text{if } \|x^* - x\| \leq \varepsilon \Rightarrow f(x^*) < f(x).$$

نقطه  $x^* \in R^n$  را مینیمم سراسری اکید تابع  $f$  گوئیم، هرگاه به ازای هر  $x \in R^n$

$$f(x^*) < f(x).$$

درحل مسئله (۱.۴.۱)، به‌دنبال یافتن یک نقطه مینیمم سراسری تابع  $f$  هستیم. اما معمولاً تعیین این نقطه و حتی مشخص کردن محل آن بسیار دشوار است. این واقعیت چه از لحاظ محاسباتی و چه از لحاظ نظری، باعث می‌شود که ما در بسیاری مواقع به نقطه مینیمم موضعی رضایت دهیم. اما به‌منظور توسعه نظریه‌ای که مستقیماً به خصوصیات نقاط مینیمم سراسری و نه مینیمم موضعی پردازد، ضروری است که نوعی از فرض‌های مربوط به تحدب معرفی شود. مفهوم تحدب در بهینه‌سازی یک مفهوم اساسی است و یک حالت خاص و مهم، بهینه‌سازی محدب است که همه جواب‌های موضعی آن، جواب‌های سراسری نیز می‌باشند.

اصطلاح تحدب هم برای مجموعه‌ها به کار می‌رود و هم برای توابع، لذا به تعاریف زیر توجه می‌کنیم.

### تعریف ۱-۴-۲ [۲]

**الف) مجموعه محدب:** مجموعه  $S \subseteq R^n$  یک مجموعه محدب ناتهی است اگر برای هر دو نقطه دلخواه

$x_1, x_2 \in S$  و هر  $\alpha$  که  $0 \leq \alpha \leq 1$  داشته باشیم

$$\alpha x_1 + (1 - \alpha)x_2 \in S.$$

**ب) تابع محدب:** تابع  $f$ ، تعریف شده روی مجموعه محدب ناتهی  $S$ ، محدب گفته می شود اگر به ازای همه

مقادیر  $x_1, x_2 \in S$  و هر  $\alpha$  که  $0 < \alpha < 1$  داشته باشیم

$$f(\alpha x_1 + (1 - \alpha)x_2) \leq \alpha f(x_1) + (1 - \alpha)f(x_2).$$

اگر به ازای هر  $\alpha$  که  $0 < \alpha < 1$  و  $x_1 \neq x_2$  داشته باشیم

$$f(\alpha x_1 + (1 - \alpha)x_2) < \alpha f(x_1) + (1 - \alpha)f(x_2).$$

آنگاه  $f$  را اکیداً محدب گوئیم.

**ج) تابع به طور یکنواخت محدب<sup>۱</sup>:** تابع  $f$  تعریف شده روی مجموعه محدب ناتهی  $S$ ،

به طور یکنواخت محدب گفته می شود اگر یک ثابت  $\mu > 0$  وجود داشته باشد به طوریکه به ازای

همه مقادیر  $x_1, x_2 \in S$  و هر  $\alpha$  که  $0 < \alpha < 1$  داشته باشیم

$$f(\alpha x_1 + (1 - \alpha)x_2) \leq \alpha f(x_1) + (1 - \alpha)f(x_2) - \frac{1}{2}\mu\alpha(1 - \alpha)\|x_1 - x_2\|^2,$$

همچنین اگر  $f$  به طور پیوسته مشتق پذیر باشد، آنگاه به سادگی می توان نشان داد که این رابطه

معادل با روابط زیر است

$$\left(\nabla f(x_1) - \nabla f(x_2)\right)^T (x_1 - x_2) \geq \mu\|x_1 - x_2\|^2. \quad (۳.۴.۱)$$

$$f(x_1) \geq f(x_2) + \nabla f(x_2)^T (x_1 - x_2) + \frac{1}{2}\mu\|x_1 - x_2\|^2. \quad (۴.۴.۱)$$

در ادامه با بیان تعدادی لم به بیان خواص توابع محدب می پردازیم.

**لم ۱-۴-۱: [۲]** تابع به طور پیوسته مشتق پذیر  $f$  روی مجموعه محدب ناتهی  $S$ ، محدب است اگر و تنها

اگر به ازای هر  $x, y \in S$  داشته باشیم

$$f(y) \geq f(x) + \nabla f(x)^T (y - x).$$

**لم ۱-۴-۲:** [۱] فرض کنید تابع  $f$  در هر نقطه  $x \in R^n$  دو بار به طور پیوسته مشتق پذیر باشد، در این صورت  $f$  روی مجموعه محدب ناتهی  $S$  مشتمل بر نقطه درونی، محدب است اگر و تنها اگر ماتریس هسی  $G$  در سراسر  $S$  نیمه معین مثبت باشد.

یکی از ابزارهای مهم در بهینه سازی، قضیه تیلور می باشد که مبنای بسیاری از روش های عددی محسوب می شود. در ادامه به بیان این قضیه می پردازیم.

**قضیه ۱-۴-۱ (قضیه تیلور):** [۳،۴] فرض کنیم  $f$  یک تابع حقیقی بر  $[a, b]$  بوده و  $n$  یک عدد صحیح مثبت باشد. اگر  $f^{(n)}$  موجود و بر  $[a, b]$  پیوسته باشد و  $f^{(n+1)}$  بر روی  $(a, b)$  وجود داشته باشد، آنگاه برای هر دو نقطه  $x$  و  $c$  در  $[a, b]$  داریم:

$$f(x) = \sum_{k=0}^n \frac{f^{(k)}(c)}{k!} (x-c)^k + E_n(x),$$

که در آن، به ازای نقطه ای مانند  $\xi$  بین  $x$  و  $c$  داریم:

$$E_n(x) = \frac{1}{(n+1)!} f^{(n+1)}(\xi) (x-c)^{n+1}.$$

بر اساس این قضیه، اگر مشتق مرتبه  $n+1$  ام تابع حقیقی  $f$  وجود داشته باشد، آنگاه می توان تابع  $f$  را با یک چند جمله ای از درجه  $n$  تقریب زد. حالت خاص  $n=0$  قضیه تیلور، اغلب در استدلال ها به قضیه مقدار میانگین معروف است.

**قضیه ۱-۴-۲ (قضیه تیلور مرتبه دوم برای توابع  $n$  متغیره):** [۱،۵] فرض کنید  $f: R^n \rightarrow R$  یک تابع  $n$  متغیره و دو بار به طور پیوسته مشتق پذیر و  $p \in R^n$  باشد. آنگاه برای برخی از مقادیر  $t \in (0,1)$  داریم:

$$\nabla f(x+p) = \nabla f(x) + \int_0^1 \nabla^2 f(x+tp) p dt.$$

به علاوه برای برخی از مقادیر  $t \in (0,1)$  داریم:

$$f(x+p) = f(x) + \nabla f(x)^T p + \frac{1}{2} p^T \nabla^2 f(x+tp) p.$$

هدف این پایان نامه ارائه الگوریتم های مناسب برای حل مسئله بهینه سازی است. اما برای محاسبه جواب بهینه قبل از هر چیز ابتدا باید با خواص نقطه بهینه آشنا شویم. قضایای زیر می تواند ما را در شناسایی نقاط مینیمم تابع  $f$  یاری کند.



## شرایط لازم مرتبه اول

**قضیه ۱-۴-۳:** [۵] فرض کنید  $f$  روی  $R^n$  به طور پیوسته مشتق پذیر باشد. اگر نقطه  $x^* \in R^n$  یک مینیم موضعی تابع  $f$  باشد، آنگاه  $\nabla f(x^*) = 0$ .

**اثبات:** برای مشاهده اثبات به [۵] مراجعه کنید. ■

مشاهده می شود که شرط  $\nabla f(x^*) = 0$  یک شرط لازم برای مینیم موضعی بودن  $x^*$  است، اما برقراری این رابطه مینیم بودن  $x^*$  را تضمین نمی نماید، نقاط صادق در شرایط فوق نقاط ایستا نامیده می شوند. به سادگی ثابت می گردد که شرط  $\nabla f(x^*) = 0$  در مورد توابع محدب، یک شرط کافی نیز می باشد.

**لم ۱-۴-۳:** [۵] فرض کنید  $f$  یک تابع محدب به طور پیوسته مشتق پذیر باشد. نقطه  $x^* \in R^n$  یک مینیم موضعی تابع  $f$  می باشد، اگر و تنها اگر  $\nabla f(x^*) = 0$ .

پیش تر بیان شد که هدف مطلوب ما در حل مسائل مینیم سازی، یافتن یک نقطه مینیم سراسری تابع  $f$  است. اما معمولاً تعیین این نقطه و حتی مشخص کردن محل آن بسیار دشوار است، از این رو در بسیاری از مواقع تنها به یافتن نقطه مینیم موضعی رضایت می دهیم. اما این امر زمانی که  $f$  یک تابع محدب باشد، متفاوت خواهد بود. قضیه زیر بیانگر این ویژگی مطلوب توابع محدب است.

**قضیه ۱-۴-۴:** [۵] فرض کنیم تابع  $f$  روی زیرمجموعه محدب  $S$  از  $R^n$  محدب باشد، آنگاه هر مینیم موضعی آن یک مینیم سراسری است.

شرایط لازم مرتبه دوم که بر حسب ماتریس هسی  $\nabla^2 f$  مرکب از مشتقات جزئی مرتبه دوم تابع  $f$  تعریف می شوند، از لحاظ نظری بسیار مهم می باشند. زیرا این شرایط علاوه بر شرط لازم  $\nabla f(x^*) = 0$ ، که نقاط دیگری به جز مینیم تابع  $f$  نیز در آن صدق می کنند، شرط دیگری را بیان می کند که مینیم تابع  $f$  باید در آن صادق باشد.

## شرایط لازم مرتبه دوم

**قضیه ۱-۴-۵:** [۵] فرض کنید تابع  $f$  دو بار به طور پیوسته مشتق پذیر است. اگر  $x^*$  مینیم موضعی تابع  $f$  باشد و  $\nabla^2 f$  بر روی یک همسایگی باز  $x^*$  پیوسته باشد، آنگاه  $\nabla f(x^*) = 0$  و  $\nabla^2 f(x^*)$  نیمه معین مثبت است.

**اثبات:** برای مشاهده اثبات به [۵] مراجعه کنید. ■

## شرایط کافی مرتبه دوم

**قضیه ۱-۴-۶:** [۵] فرض کنید تابع  $f$  دو بار به طور پیوسته مشتق پذیر است. اگر نقطه  $x^*$  موجود باشد به طوری که  $\nabla^2 f$  بر روی یک همسایگی باز  $x^*$  پیوسته بوده و  $\nabla f(x^*) = 0$  و  $\nabla^2 f(x^*)$  معین مثبت باشد، آنگاه  $x^*$  یک مینیمم موضعی اکید برای تابع  $f$  است.

**اثبات:** برای مشاهده اثبات به [۵] مراجعه کنید. ■

از این پس و در سراسر این پایان نامه همواره فرض می‌کنیم تابع  $f$  دو بار به طور پیوسته مشتق پذیر است مگر اینکه خلاف آن ذکر شود.

## ۱-۵ الگوریتم‌های کاهش‌ی برای بهینه‌سازی نامقید

اکنون به هدف اصلی که ساخت الگوریتم‌های مناسب برای حل مسئله بهینه‌سازی نامقید که دارای فرم کلی زیر است باز می‌گردیم.

$$\min_{x \in R^n} f(x) \quad (۱.۵.۱)$$

ایده اصلی بیشتر الگوریتم‌های موجود برای حل مسئله فوق تولید یک دنباله کاهش‌ی  $\{x_k\}$ ، با شروع از یک نقطه ابتدایی مانند  $x_0$  و استفاده از یک طرح تکراری برای تولید دنباله است، که هدف مطلوب آن همگرایی به سمت نقطه ایستا است. زیرا در این صورت احتمالاً شرایط مرتبه دوم برقرار خواهند شد. لازم است قبل از هرگونه بحثی مفهوم الگوریتم کاهش‌ی را توضیح دهیم. در ادامه برای سهولت در نمایش، اگر  $x_k$  تکرار اخیر و  $x^*$  جواب مینیمم یا نقطه ایستای (۱.۵.۱) باشد آنگاه  $f(x_k)$  را با  $f_k$ ،  $\nabla f(x_k)$  را با  $g_k$ ،  $\nabla^2 f(x_k)$  را با  $G_k$  و  $f(x^*)$  را با  $f^*$  نمایش می‌دهیم.

در فرایند تکراری حل مسئله (۱.۵.۱) به دنبال یک جهت  $d_k$  و یک طول گام  $\alpha_k > 0$  برای تعریف  $x_{k+1}$  به صورت زیر هستیم

$$x_{k+1} = x_k + \alpha_k d_k. \quad (۲.۵.۱)$$

به طوری که  $f(x_{k+1}) \leq f(x_k)$ . این فرآیند نیازمند انتخاب مناسب  $d_k$  و  $\alpha_k$  می‌باشد. در راستای یافتن  $d_k$  مناسب بسط تیلور تابع  $f$  حول  $x_k$  در راستای  $d_k$  را به صورت زیر در نظر بگیریم:

$$f(x_k + \alpha_k d_k) = f_k + \alpha_k g_k^T d_k + \frac{1}{2} \alpha_k^2 d_k^T G_k d_k + O(\|d_k\|^3).$$

اگر  $g_k^T d_k < 0$  و  $\alpha_k$  به اندازه کافی کوچک باشد، آنگاه  $f(x_k + \alpha_k d_k) \leq f_k$ . بنابراین شرط  $g_k^T d_k < 0$

یک شرط کافی برای این است که  $f$  در راستای  $d_k$  قابلیت کاهش داشته باشد. در این حالت اصطلاحاً گفته می شود  $d_k$  یک جهت کاهشی است. پس از تعیین جهت کاهشی  $d_k$ ، طول گام  $\alpha_k$  در فرایند تکراری (۲.۵.۱)، با استفاده از جستجوی خطی که در واقع نوعی بهینه سازی یک متغیره است، تعیین می شود

و بدیهی ترین روش انتخاب طول گام  $\alpha_k$ ، جستجوی خطی دقیق می باشد، یعنی

$$\alpha_k = \underset{\alpha > 0}{\text{Arg min}} f(x_k + \alpha d_k).$$

توجه داریم که الگوریتم عمومی جریان کاهشی برای مینیم سازی تابع  $f$  را می توان به صورت زیر بیان کرد.

### ۱-۵-۱ الگوریتم عمومی:

**ورودی الگوریتم:** پارامتر دقت  $\varepsilon > 0$  و بردار آغازین  $x_0$ .

گام (۰): قرار ده  $x = x_0, k = 0$ .

گام (۱): یک جهت جستجوی کاهشی  $d_k$  را پیدا کن.

اگر جهتی کاهشی موجود نیست توقف. ( $x_k$  یک کاندید برای جواب بهینه است).

گام (۲): (جستجوی خطی دقیق)  $\alpha_k$  را به گونه ای محاسبه کنید که

$$\alpha_k = \underset{\alpha > 0}{\text{Arg min}} f(x_k + \alpha d_k).$$

گام (۳): قرار ده  $x_{k+1} = x_k + \alpha_k d_k$ .

گام (۴): در صورت برقراری معیار توقف، توقف کن، در غیر این صورت  $k = k + 1$  و به گام (۱) برو.

**تذکر ۱-۵-۱:** انتخاب مناسب بردار آغازین  $x_0$  در الگوریتم عمومی یکی از عناصر حیاتی در همه الگوریتم ها است. هر الگوریتم تکراری با مشخص کردن یک نقطه آغازین شروع می شود. اگر برای هر نقطه دلخواه آغازین، الگوریتم همواره دنباله ای از نقاط را تولید کند که همگرا به یک جواب شوند، آنگاه الگوریتم را «همگرای سراسری» نامند. قطعاً تمام الگوریتم ها این خاصیت مطلوب را ندارند. در واقع بسیاری از مهم ترین الگوریتم ها برای حل مسائل بهینه سازی غیرخطی همگرای سراسری نیستند و در نتیجه گاهی دنباله هایی تولید می کنند که یا اصلاً همگرا نمی شوند و یا همگرایی به سمت نقاطی است که جواب مسئله نیستند.

یکی دیگر از خواص مطلوب برای الگوریتم های بهینه سازی نامقید، این است که بتوانیم ثابت کنیم الگوریتم برای مسائل درجه دوم در تعداد متناهی تکرار به جواب  $x^*$  همگرا باشد، در این صورت گوئیم الگوریتم دارای «خاصیت مدل درجه دوم» است. این ویژگی از این نظر مطلوب است که با توجه به قضیه تیلور داریم

هر تابع در یک همسایگی مناسب  $x^*$  بر یک مدل درجه دوم انطباق دارد.

یکی از عناصر تاثیرگذار در الگوریتم‌های مینیم سازی، چگونگی تولید جهت جستجوی  $d_k$  است زیرا با توجه به گام (۱)، الگوریتم عمومی برای ساختن دنباله مورد نظر، به یک جهت جستجو نیاز دارد. اکنون به طور مختصر به بررسی دو نوع از مهم‌ترین الگوریتم‌های تکراری کاهشی در بهینه‌سازی غیرخطی می‌پردازیم.

### ۱-۵-۱ روش گرادیان

یکی از قدیمی‌ترین و شناخته‌شده‌ترین روش‌ها برای مینیم سازی یک تابع چند متغیره، روش تندترین کاهش است که به روش گرادیان نیز مشهور می‌باشد. این روش از دیدگاه نظری دارای اهمیت فوق العاده‌ای می‌باشد زیرا یکی از ساده‌ترین روش‌هایی است که برای آن تحلیل قانع کننده‌ای وجود دارد. انگیزه برای طرح الگوریتم‌های پیشرفته‌تر اغلب از تلاش برای اصلاح روش اساسی گرادیان به نحوی که الگوریتم‌های جدید دارای خواص همگرایی بهتری باشند، به وجود آمده‌اند. بنابراین روش گرادیان نه تنها اولین روشی است که برای حل یک مسئله جدید امتحان می‌شود، بلکه مرجعی برای سنجیدن سایر روش‌ها نیز می‌باشد [۱].

فرض می‌کنیم  $f$  دارای مشتقات جزئی مرتبه اول پیوسته در  $R^n$  باشد. در این روش به بردار گرادیان  $f$  نیاز داریم و در رابطه (۲.۵.۱) قرار می‌دهیم

$$d_k = -\nabla f(x_k) \triangleq -g_k.$$

به وضوح مشاهده می‌شود که جهت تولید شده توسط روش گرادیان در شرط کاهشی  $g_k^T d_k < 0$  صدق می‌کند.

این روش اگرچه هزینه محاسباتی کمی دارد اما سرعت همگرایی آن خطی است و حتی ممکن است دچار پدیده زیگزاگ گردد، عموماً این الگوریتم دور از جواب نتایج مطلوبی تولید می‌نماید. همچنین این الگوریتم دارای خاصیت مدل درجه دوم نیست. در جهت رفع مشکلات روش گرادیان، روش‌های گرادیان مزدوج ارائه شده‌اند که فصل دوم به بررسی این روش‌ها و ویژگی‌های آن‌ها اختصاص یافته است.

### ۱-۵-۲ روش نیوتن

برای معرفی روش نیوتن ابتدا فرض می‌کنیم که تابع  $f$  دو بار به‌طور پیوسته مشتق پذیر و محدب اکید است. جهت جستجوی نیوتن در بهینه‌سازی چند بعدی بر پایه مینیم کردن یک تقریب مرتبه دوم تابع  $f$  است. بنابراین با به کار بردن سه جمله اول بسط تیلور تابع  $f$ ، تقریب مجذوری  $f$  را حول نقطه  $x_k$  به دست آورده

و آنرا مینیمم می کنیم.

$$q(x) \cong f_k + g_k^T(x - x_k) + \frac{1}{2} (x - x_k)^T \nabla^2 f(x_k)(x - x_k).$$

می توان نشان داد  $q(x)$  محدب اکید است اگر و تنها اگر  $\nabla^2 f(x_k)$  معین مثبت باشد و مینیمم مقدار  $q(x)$  وقتی که گرادیان آن مساوی بردار صفر باشد، به دست می آید. به عبارت دیگر در نقطه  $x_k$  داریم

$$\nabla q(x) = g_k + \nabla^2 f(x_k)(x - x_k) = 0.$$

بنابراین در روش نیوتن که دنباله  $\{x_k\}$  به صورت  $x_{k+1} = x_k - G_k^{-1}g_k$  تولید می شود، اگر نقطه آغازین به اندازه کافی نزدیک به نقطه مینیمم باشد آنگاه روش های نیوتن همگرایی مجذوری با طول گام کامل (بدون هیچ جستجو خطی  $\alpha = 1$ ) را نتیجه می دهند.

### ۱-۵-۲ الگوریتم نیوتن:

گام (۱): از نقطه آغازین  $x_0$  شروع کن.

گام (۲): با محاسبه  $G_k = \nabla^2 f(x_k)$  و  $g_k = \nabla f(x_k)$  قرار ده  $d_k = -G_k^{-1}g_k$  و  $x_{k+1} = x_k + d_k$ .

گام (۳): تا رسیدن به دقت مورد نظر فرایند را تکرار کن.

**تذکر ۱-۵-۱:** عملاً به جای محاسبه  $d_k$  از رابطه  $d_k = -G_k^{-1}g_k$  را یک جواب دستگاه  $G_k d_k = -g_k$  در نظر می گیریم. البته توجه داریم در صورتیکه  $G_k$  وارون پذیر نباشد نمی توان جهت جستجوی  $d_k$  را محاسبه نمود.

**تذکر ۱-۵-۲:** واضح است که جهت نیوتن در صورتی کاهشی است که  $g_k^T G_k g_k > 0$ ، از طرفی در  $x^*$ ،  $G^*$  معین مثبت است و لذا بنابر پیوستگی مشتق مرتبه دوم  $G_k$  نیز معین مثبت است. لذا کاهشی بودن الگوریتم در نزدیکی جواب تضمین می گردد، اما در غیر این صورت ممکن است جهت نیوتن کاهشی نباشد، به خصوص در حالتی که  $G_k$  وارون پذیر باشد ولی معین مثبت نباشد. در این حالت با اینکه جهت به دست آمده از روش نیوتن موجود است اما ممکن است کاهشی نباشد. در این صورت ایده این است که به جای  $G_k^{-1}$  یک تقریب معین مثبت از آن مانند  $H_k$  جایگزین کنیم و بنابراین داریم  $d_k = -H_k g_k$ .

**تذکر ۱-۵-۳:** الگوریتم نیوتن از جستجوی خطی استفاده نمی کند زیرا طول گام آن کامل است. لذا در بعضی موارد شرط کاهشی بودن نقض می گردد. اما بایستی توجه داشت که حتی در صورت معین مثبت بودن  $G_k$  هیچ تضمینی برای کاهش در تابع هدف وجود ندارد، و معین مثبت بودن  $G_k$  تنها یک جهت کاهشی تولید می کند. در این حالت ممکن است یک نسخه الگوریتم نیوتن به همراه جستجوی خطی، پیشنهادی

مناسب برای تولید الگوریتم کاهش می باشد که این روش نیوتن پرشی<sup>۱</sup> نامیده می شود، در این صورت  
 $x_{k+1} = x_k + \alpha_k d_k$  که در آن  $\alpha_k$  طول گام است. در این حالت  $\alpha_k \neq 1$  است، زیرا روش نیوتن دارای  
 طول گام یک می باشد.

**تذکره ۱-۵-۴:** عموماً در نزدیکی جواب،  $G_k$  معین مثبت است. بنابراین برای حل دستگاه  $G_k d_k = -g_k$   
 می توان از روش تجزیه چولسکی استفاده کرد ( $G_k = L_k L_k^T$ ) که نیاز به  $O(\frac{1}{6}n^3)$  عملیات محاسباتی دارد.  
 مزیت تجزیه چولسکی این است که برای محاسبه  $G_{k+1}$  از  $G_k$ ، دیگر  $O(\frac{1}{6}n^3)$  عملیات لازم نیست بلکه  
 می توان  $L_{k+1} L_{k+1}^T$  را از  $L_k L_k^T$  با  $O(n^2)$  عملیات محاسبه نمود [۶].

**تذکره ۱-۵-۵:** هزینه محاسبات روش نیوتن بالا می باشد، زیرا در هر مرحله نیاز به محاسبه  $n$  مشتق مرتبه  
 اول برای محاسبه  $g_k$  و  $n^2$  مشتق مرتبه دوم برای محاسبه  $G_k$  دارد. این مشکل ما را به سمت خانواده  
 روش های شبه نیوتن سوق می دهد. بنابراین از یک تقریب  $H_k$  برای  $G_k^{-1}$  استفاده می کنیم. به طوریکه  $H_k$  یک  
 ماتریس معین مثبت باشد، که هم کاهش بودن  $d_k$  را تضمین می کند و هم مشکل هزینه محاسبات  $G_k$  را  
 برطرف می سازد. در واقع محاسبه ماتریس هسی و معکوس هسی نسبت به محاسبه گرادیان خیلی پرهزینه تر  
 است.

در راستای رفع مشکلات روش نیوتن و در عین حال حفظ خواص مطلوب آن، مانند سرعت همگرایی بالای  
 این روش، روش های مختلفی ارائه گردیده است که در این راستا می توان به روش های شبه نیوتن اشاره نمود.  
 در ادامه با توجه به اینکه برخی از الگوریتم های بیان شده در فصول آینده با استفاده از خواص روش های شبه  
 نیوتنی به دست آمده اند، لازم به نظر می رسد که این روش ها را با تفصیل بیشتری مورد بررسی قرار دهیم.

### ۱-۵-۳ روش های شبه نیوتن

از آنجا که محاسبه و به کارگیری ماتریس هسی غیر عملی یا پرهزینه است، ایده زیربنایی روش های شبه نیوتن  
 بر اساس استفاده از یک تقریب ماتریس وارون هسی به جای وارون حقیقی مورد نیاز در روش نیوتن قرار  
 دارد. شکل این تقریب در روش های متفاوت تغییر می کند، از ساده ترین شکل که در سرتاسر فرایند تکراری  
 ثابت می ماند تا شکل های پیشرفته تر که تقریب های بهتری بر پایه اطلاعات جمع آوری شده در خلال فرایند  
 کاهش می ساخته می شود. در حالت ایده آل این تقریب ها به وارون هسی در نقطه جواب همگرا می شوند. در  
 روش های شبه نیوتن می توان هم ماتریس هسی  $G_k$  را به وسیله ماتریس  $B_k$  تقریب زد و هم ماتریس  $G_k^{-1}$  را

---

1-Damped Newton

به وسیله ماتریس  $H_k$  تقریب زد. در واقع یک ایده مناسب این است که به جای اینکه  $G_k$  را تقریب زده و سپس وارون تقریبی آنرا به دست آوریم، همان بهتر است که در ابتدا وارون  $G_k$  را به وسیله  $H_k$  تقریب بزنیم. چون ما به یک الگوریتم کاهشی نیاز داریم، پس بهتر است که  $H_k$  معین مثبت باشد. از اینرو ایده مناسب این است که یک تقریب معین مثبت  $H_k$  از  $G_k^{-1}$  بیابیم. در نتیجه با توجه به مطالب بیان شده، مهم ترین مسئله در روش های شبه نیوتن ساخت ماتریس تقریبی  $H_k$  است. در حالت کلی می توان الگوریتم عمومی شبه نیوتن را به صورت زیر بیان کرد:

### ۱-۵-۳ الگوریتم شبه نیوتن:

گام (۰): با بردار آغازین  $x_0$  و ماتریس وارون پذیر  $H_0$  شروع کن.

گام (۱): قرارداده  $d_k = -H_k g_k$ .

گام (۲): با یک جستجوی خطی در راستای  $d_k$ ، طول گام  $\alpha_k$  را محاسبه کن. سپس قرارداده

$$x_{k+1} = x_k + \alpha_k d_k$$

گام (۳): در صورت برقراری شرایط توقف، توقف کن.

گام (۴):  $H_{k+1}$  را با استفاده از  $H_k, g_k, d_k$  بهنگام کنید.

### تذکره ۱-۵-۶:

۱. در گام (۴) علاقه مندیم که  $H_{k+1}$  معین مثبت بوده و نسبت به  $H_k$  برتری داشته باشد. توجه داریم که اگر

$$d_k^T g_k = -g_k^T H_k g_k < 0 \text{ زیرا } d_k \text{ یک جهت کاهشی است.}$$

۲. در حالت کلی کافی است  $H_0$  را یک ماتریس معین مثبت  $n \times n$  قرار دهیم. اما معمولاً به دلیل اطلاعات

کمی که از مسئله در اختیار داریم، بهتر است این هزینه را به خود تحمیل نکرده و قرار دهیم  $H_0 = I$ ، در این صورت جهت ابتدایی همان جهت گرادیان است.

۳. ایده مناسب در گام سوم برای تبدیل  $H_k$  به  $H_{k+1}$  استفاده از رابطه معروف سکانت می باشد. ما نیاز

داریم که  $H_{k+1}$  شبیه  $G_{k+1}^{-1}$  رفتار کند، لذا از بسط تیلور بردار گرادیان حول نقطه  $x_{k+1}$  داریم

$$g(x) \cong g_{k+1} + G_{k+1}(x - x_{k+1}).$$

اکنون قراردادادن  $x = x_k$ ،  $y_k = g_{k+1} - g_k$  و  $s_k = x_{k+1} - x_k$  در رابطه اخیر نتیجه می دهد:

$$G_{k+1} s_k \cong y_k.$$

در واقع  $y_k$  مقدار  $G_{k+1} s_k$  را تقریب می زند. از اینرو می توان نوشت  $G_{k+1}^{-1} y_k \cong s_k$ . ما می خواهیم  $H_{k+1}$  را

به عنوان تقریب  $G_{k+1}^{-1}$  به کار ببریم. پس کافی است  $H_{k+1}$  را طوری محاسبه کنیم که در رابطه زیر صدق

کند.

$$H_{k+1}y_k = s_k. \quad (۳.۵.۱)$$

این معادله به معادله سکانت (استاندارد) معروف می‌باشد.

با توجه به الگوریتم عمومی شبه نیوتن دیده می‌شود که مهم‌ترین گام الگوریتم چگونگی تولید ماتریس  $H_{k+1}$  از  $H_k$  است که به بهنگام سازی ماتریس هسی معروف است. در زیر سه نمونه از ساده‌ترین طرح‌های پیشنهادی به منظور بهنگام سازی ماتریس  $H_{k+1}$  را به‌طور مختصر مرور می‌کنیم. [۷]

### ۱-۳-۵-۱ تصحیح رتبه یک *SRI*

در این روش در هر مرحله فرض می‌کنیم  $H_{k+1} = H_k + E_k$  که در آن  $E_k$  را یک ماتریس با مرتبه یک تعریف می‌کنیم که تقریب وارون را بهنگام سازد. به دلیل تقارن مورد نیاز قرار می‌دهیم:

$$H_{k+1} = H_k + E_k = H_k + \alpha uu^T.$$

ما نیاز داریم  $H_{k+1}$  در رابطه سکانت صدق کند، یعنی  $H_{k+1}y_k = s_k$ . با انجام محاسبات لازم، رابطه بهنگام رتبه یک (*SRI*) به صورت زیر به دست می‌آید:

$$H_{k+1} = H_k + \frac{(s_k - H_k y_k)(s_k - H_k y_k)^T}{(s_k - H_k y_k)^T y_k}. \quad (۱.۳.۵.۱)$$

که اگر  $H_k$  متقارن باشد،  $H_{k+1}$  نیز متقارن است.

برای رابطه بهنگام رتبه یک (*SRI*) دو حالت ممکن است رخ دهد:

(۱)  $(s_k - H_k y_k)^T y_k \neq 0$ . در این صورت از روند فوق یک بهنگام رتبه یک منحصر بفرد به وجود می‌آید. البته اگر  $(s_k - H_k y_k)^T y_k$  ناصفر باشد، اما بسیار کوچک باشد، این امر ممکن است منجر به مشکلات عددی گردد.

(۲)  $(s_k - H_k y_k)^T y_k = 0$ . در این صورت دو حالت را در نظر می‌گیریم: یا  $s_k = H_k y_k$  که در این حالت کافیت قراردهیم  $H_{k+1} = H_k$ ، یعنی به بهنگام سازی نیازی نیست و ماتریس  $H_k$  خاصیت مطلوب را دارد. در غیر این صورت هیچ فرمول بهنگام رتبه یکی موجود نیست که در معادله سکانت صدق کند و در نتیجه باید از فرمول‌های بهنگام دیگری کمک گرفت.

این بهنگام با وجود سادگی دارای مشکلاتی است، اول اینکه معین مثبت بودن را فقط در صورتی حفظ



می کند که  $(s_k - H_k y_k)^T y_k > 0$ . برقراری این شرط را نمی توان تضمین کرد. در واقع حتی تضمینی برای اینکه  $(s_k - H_k y_k)^T y_k \neq 0$  موجود نیست، یعنی ممکن است رابطه خوش تعریف نباشد. دوماً همان طور که بیان شد در صورتیکه  $(s_k - H_k y_k)^T y_k \neq 0$  اما بسیار کوچک باشد، این امر موجب رشد درایه های ماتریس  $H_{k+1}$  شده و می تواند سبب مشکلاتی از جمله ناپایداری عددی روش گردد. در عمل مشاهده می شود که بهنگام تولید شده از روش (SRI) تقریب های خوبی برای ماتریس هسی تولید می کند و نتایج آن ها در بسیاری از موارد از بهنگام رتبه دو بهتر است. اما چون راهی برای تضمین معین مثبت بودن وجود ندارد، ناچار هستیم از بهنگام رتبه دو استفاده کنیم.

### ۱-۳-۲ روش دیویدان-فلچر-پاول (DFP)

یکی از قدیمی ترین و هوشمندانه ترین شیوه ها برای ساختن وارون هسی یا خود هسی، شیوه ای است که ابتدا Davidon در سال ۱۹۵۹ آنرا پیشنهاد کرد و سپس Fletcher و Powell آنرا تکامل بخشیدند. در هر گام وارون هسی با جمع دو ماتریس متقارن رتبه یک بهنگام می شود و به این دلیل اغلب به روش تصحیح رتبه دو معروف است. این روش دارای این خاصیت جذاب و مطلوب است که برای یک تابع هدف درجه دوم، هم زمان با ساختن ماتریس هسی، جهت های روش گرادیان مزدوج<sup>۱</sup> را تولید می کند. به منظور به دست آوردن این رابطه قرار می دهیم.

$$H_{k+1} = H_k + auu^T + cvv^T. \quad (۲.۳.۵.۱)$$

باز هم هدف برقراری رابطه سکانت  $H_{k+1} y_k = s_k$  است. پس از انجام محاسبات لازم، به رابطه بهنگام DFP به صورت زیر می رسیم.

$$H_k^{DFP} = H_k + \frac{s_k s_k^T}{s_k^T y_k} - \frac{H_k y_k y_k^T H_k}{y_k^T H_k y_k}. \quad (۳.۳.۵.۱)$$

قضیه زیر یکی از خواص مهم بهنگام DFP را مطرح می نماید.

**قضیه ۱-۳-۳:** [۷] اگر  $H_k$  معین مثبت و  $s_k^T y_k > 0$ ، آنگاه  $H_{k+1}$  نیز معین مثبت است.

**تذکر ۱-۳-۷:** توجه کنید که شرط  $s_k^T y_k > 0$  را می توان به وسیله شرایط جستجوی خطی به مسئله تحمیل کرد. در ادامه به برخی از خواص مطلوب الگوریتم DFP می پردازیم.

(a) در مورد توابع درجه دوم با هسی معین مثبت

(۱) الگوریتم شبه نیوتن  $DFP$  با استفاده از جستجوی خطی دقیق در هر تکرار، در حداکثر  $n+1$  تکرار به جواب می‌رسد  $g_{n+1} = 0$  و  $H_{n+1} = G^{-1}$ .

(۲) رابطه سکانت برای قدم‌های پیشین حفظ می‌گردد یعنی برای  $i = 1, 2, \dots, n$  و برای  $j = 1, 2, \dots, i-1$  رابطه  $H_i y_j = s_j$  همواره برقرار است.

(۳) اگر  $H_0 = I$  آنگاه مسیرهای تولید شده همان مسیرهای گرادیان مزدوج نسبت به ماتریس هسی  $G$  هستند. (b) خواص الگوریتم  $DFP$  در مورد توابع عمومی

(۱) در هر مرحله  $3n^2 + O(n)$  عملیات اصلی نیاز داریم.

(۲) مرتبه همگرایی زیرخطی است.

(۳) با جستجوی خطی دقیق همگرایی سراسری در مورد توابع محدب ثابت شده است.

### ۱-۳-۵-۳ روش برویدن-فلچر-گلدفارب-شانو ( $BFGS$ )

فرمول کلی تصحیح رتبه دو متقارن، به منظور بهنگام سازی ماتریس  $H_{k+1}$ ، به صورت زیر می‌باشد:

$$H_{k+1} = H_k + [u \ v] \begin{bmatrix} a & b \\ b & c \end{bmatrix} [u \ v]^T.$$

یعنی:

$$H_{k+1} = H_k + auu^T + cvv^T + b(vu^T + uv^T). \quad (۴.۳.۵.۱)$$

اگر در رابطه (۴.۳.۵.۱)، قرار دهیم  $b = 0$ ، آنگاه تصحیح رتبه دو متقارن (۲.۳.۵.۱) به دست می‌آید. مشابه

روش  $DFP$  به منظور برقراری رابطه سکانت  $H_{k+1} y_k = s_k$ ، پس از انجام محاسبات لازم و قراردادن

$c = 0$ ، رابطه بهنگام  $BFGS$  برای ماتریس  $H_{k+1}$  به صورت زیر به دست می‌آید:

$$H_{k+1}^{BFGS} = H_k + \left( 1 + \frac{y_k^T H_k y_k}{y_k^T s_k} \right) \frac{s_k s_k^T}{s_k^T y_k} - \left( \frac{s_k y_k^T H_k + H_k y_k s_k^T}{y_k^T s_k} \right). \quad (۵.۳.۵.۱)$$

**تذکره ۱-۵-۹:** بهنگام  $BFGS$  تمامی خواص مطلوب بهنگام  $DFP$  را دارا می‌باشد. به علاوه در صورت

استفاده از جستجوی خطی غیر دقیق، روش  $BFGS$  همگرایی سراسری است، در حالیکه این مطلب در مورد

روش  $DFP$  هنوز اثبات نشده است.

**تذکره ۱-۵-۱۰:** با توجه به تذکره ۱-۵-۶ در صورتیکه از ماتریس  $B_{k+1}$  برای تقریب ماتریس هسی  $G_{k+1}$

استفاده کنیم، معادله سکانت به صورت زیر خواهد بود:

$$B_{k+1} s_k = y_k. \quad (۶.۳.۵.۱)$$

راه دیگری که برای تبدیل یک فرمول بهنگام سازی  $H$  به فرمولی برای  $B$  یا بالعکس وجود دارد، گرفتن

وارون است. در نتیجه اگر از رابطه (۵.۳.۵.۱) وارون بگیریم، فرمول بهنگام سازی زیر را برای ماتریس  $B_{k+1}$  داریم:

$$B_{k+1}^{BFGS} = B_k + \frac{y_k y_k^T}{s_k^T y_k} - \frac{B_k s_k s_k^T B_k}{s_k^T B_k s_k}. \quad (۷.۳.۵.۱)$$

فرمول بهنگام سازی اخیر برای ماتریس  $B_k$  به فرمول بهنگام سازی  $BFGS$  مشهور است. به طور مشابه گرفتن وارون از رابطه بهنگام سازی (۳.۳.۵.۱) نتیجه می دهد:

$$B_k^{DFP} = B_k + \left(1 + \frac{s_k^T B_k s_k}{s_k^T y_k}\right) \frac{y_k y_k^T}{y_k^T s_k} - \left(\frac{y_k s_k^T B_k + B_k s_k y_k^T}{s_k^T y_k}\right). \quad (۸.۳.۵.۱)$$

لازم به ذکر است که اگر در رابطه (۵.۳.۵.۱) نقش  $H$  را با  $B$ ، و نقش  $s$  را با  $y$  عوض کنیم، رابطه بهنگام سازی (۸.۳.۵.۱) به دست می آید، که در اصطلاح به این عمل مکمل گیری گفته می شود. به طور مشابه مکمل رابطه (۳.۳.۵.۱) نیز رابطه بهنگام سازی (۷.۳.۵.۱) خواهد بود. [۲]

## ۶-۱ جستجوی خطی

جستجوی خطی در واقع روشی برای تعیین طول گام  $\alpha_k$  در فرایند تکراری (۲.۵.۱) می باشد. بدیهی ترین روش انتخاب طول گام  $\alpha_k$ ، جستجوی خطی دقیق می باشد، یعنی  $\phi(\alpha)$

$$\alpha_k = \underset{\alpha > 0}{\text{Arg min}} f(x_k + \alpha d_k).$$

اما به دلیل پرهزینه بودن محاسبه دقیق  $\alpha_k$ ، می توان  $\alpha_k$  را یک تقریب از مینیمم کننده دقیق مسئله فوق در نظر گرفت که منجر به جستجوی خطی غیر دقیق می گردد. البته در جهت برقراری همگرایی موضعی یا سراسری مجبوریم شرایطی را به  $\alpha_k$  تحت عنوان شرایط جستجوی خطی اعمال کنیم. جستجوی خطی در حقیقت به معنی بهینه سازی تک بعدی است. از آنجا که تابع  $\phi(\alpha) = f(x_k + \alpha d_k)$  یک تابع تک متغیره است بنابراین مسئله ما به مسئله پیدا کردن مینیمم تابع تک متغیره  $\phi(\alpha)$  تبدیل می شود، و اگر این تابع مشتق پذیر باشد باید یک صفر از  $\phi'(\alpha)$  را بیابیم. بنابراین یک دسته از روش های جستجوی خطی، همان روش های حل معادلات غیر خطی هستند.

روش های جستجوی خطی را می توان به سه دسته کلی زیر تقسیم کرد، که هر یک از دسته ها خود شامل روش های مختلفی می باشند.

۱. روش‌های بدون استفاده از مشتق: جستجوی یکنواخت، نسبت طلایی، جستجوی فیبوناچی.

۲. روش‌های استفاده کننده از مشتق: تنصیف، نیوتن، سکانت، درونیابی.

۳. روش‌های عملی و ابتکاری: جستجوی خطی غیر دقیق، جستجوی خطی با برآزش منحنی.

هر کدام از روش‌های بیان شده دارای ویژگی‌های خاص خود بوده و نیز دارای خواص همگرایی ویژه‌ای می‌باشند و برای حل دسته‌ای از مسائل بهینه‌سازی نامقید مناسب هستند، که این دلیل اصلی توسعه روش‌های جستجوی خطی می‌باشد.

### شرایط جستجوی خطی

چون جستجوی خطی دقیق از نظر محاسباتی پرهزینه می‌باشد، از اینرو اغلب استراتژی‌ها بر اساس جستجوی خطی غیر دقیق استواراند، به طوری که برای محاسبه یک تقریب خوب  $\alpha$  هزینه کمی نیاز باشد. دسته‌ای از روش‌های جستجوی خطی موسوم به *Typical line search* یک دنباله از کاندیدها را برای  $\alpha$  معرفی می‌کنند و یک روند تکراری را تا جایی ادامه می‌دهند که الگوریتم به یک مقدار مناسب  $\alpha$  دست یابد. این جستجوها عموماً به دو مرحله تقسیم می‌شوند:

(۱) پیمایش معکوس<sup>۱</sup>

(۲) درونیابی<sup>۲</sup>

در مرحله اول، یک بازه پذیرفتنی شامل  $\alpha_k$  پیدا می‌شود و در گام دوم از بازه تولید شده  $\alpha$ ، طول گام مناسب انتخاب می‌گردد. جستجوهای خطی تقریبی در اکثر موارد کارایی نسبتاً خوبی دارند، اما ممکن است خواص مطلوب جستجوهای خطی دقیق را نداشته باشند و احتمالاً موجب ازدست رفتن ویژگی‌های تئوریک الگوریتم مانند همگرایی سراسری، همگرایی موضعی و نوع همگرایی شوند. هدف ما تقریب مناسب  $\alpha_k$  است، اما باید  $\alpha_k$  را به گونه‌ای تقریب بزنیم که خواص  $\alpha_k$  تقریبی، شبیه  $\alpha_k$  دقیق باشد یا حداقل شرایط مورد نظر را داشته باشد. مهم‌ترین شرطی که روی  $\alpha_k$  اعمال می‌شود این است که نیاز داریم یک کاهش مناسب در  $f$  اتفاق بیفتد، یعنی  $f(x_k + \alpha_k d_k) \leq f(x_k)$ . اما می‌توان نشان داد که این شرط کافی نیست و ممکن است با اعمال این شرط دنباله از همگرا بودن به مینیمم کننده خود عاجز باشد. برای جلوگیری از این مشکلات نیاز داریم شرایطی اعمال کنیم که کاهش کافی را ایجاد کند. در ادامه به بیان چند مورد از این شرایط می‌پردازیم.

---

1-Backtracking  
2-Interpolation