



شبکه های عصبی

استاد: محمد باقر منهج



• فصل هفتم

- مقدمه
- مبانی بهینه سازی و نقاط بهینه
- روشهای می نیمم سازی
- یادگیری ویدرو-هوف و شبکه آدالاین
- الگوریتم LMS
- کاربرد شبکه آدالاین در فیلترهای تطبیقی



فصل ۷

شبکه های آدالاین و یادگیری LMS



مقدمه

- شبکه آدالاین با قانون یادگیری ویدرو – هوف (معروف به قانون LMS) در سال ۱۹۶۰ و بعد از شبکه پرسپترون با قانون یادگیری SLPR به وجود آمد.
- شبکه آدالاین شبیه پرسپترون است ولی با تابع تبدیل خطی (به جای آستانه دو مقداره)
- محدودیت شبکه های پرسپترون و آدالاین:
 - فقط توانایی طبقه بندی الگوهای را دارند که به طور خطی از هم جداپذیرند.
- قانون SLPR:
 - همگرایی به یک جواب را در صورت وجود تضمین میکند.
 - نسبت به نویز خیلی حساس است، زیرا خط مرزی خیلی نزدیک الگوهای یادگیری است.
- قانون LMS:
 - خیلی قویتر از SLPR
 - دارای کاربردهای فراوان در مهندسی و به خصوص پردازش سیگنال



مقدمه

• شبکه های آدالاین

- مناسب برای **تقریب خطی** یک تابع یا اجرای عمل شناسایی الگو
- دارای منحنی سطح خطای اجرایی **سه‌موی**
- دارای مزیت برخورداری از **یک نقطه مینیمم**
- یادگیری از نوع **با ناظر**
- پارامترهای شبکه به نحوی تنظیم می شوند که شاخص اجرایی میانگین مربعات خطا **بهینه** شود.
- قانون یادگیری **LMS** تقریبی از الگوریتم بیشترین شیب در حداقل کردن شاخص اجرایی
- **حتی در صورت عدم وجود جواب** (در این حالت قانون **SLPR** همگرا نخواهد شد) ، باز به جایی که میانگین مربعات خطا حداقل است، **همگرا می شود**.
- نسبت به نویز کمتر حساس



مبانی بهینه سازی و نقاط بهینه

- پایه همه تکنیکهای یادگیری از نوع عملکردی
- در **یادگیری عملکردی** پارامترهای شبکه به نحوی تنظیم می شوند که **عملکرد شبکه بهینه** شود.
- **قدم اول:** تعریف عملکرد و **تعیین شاخص عملکرد**. (معمولا سطح اجرایی میانگین مربعات خطا)
- **قدم دوم:** **جستجو** در فضای پارامترهای شبکه برای تنظیم آنها به طوریکه معیار اجرایی عملکرد کاهش یابد.



مبانی بهینه سازی: بسط تیلور و تقریب توابع

- بسط تیلور تابع اسکالر $F(\underline{x})$ با متغیر برداری \underline{x}

$$F(\underline{x}) = F(\underline{x}^*) + \nabla_{\underline{x}} F^T(\underline{x}^*)(\underline{x} - \underline{x}^*) + \frac{1}{2}(\underline{x} - \underline{x}^*)^T \nabla_{\underline{x}}^2 F(\underline{x}^*)(\underline{x} - \underline{x}^*) + \dots$$

- بردار گرادیان و ماتریس هسیان تابع F به ترتیب برابرند با:

$$\nabla_{\underline{x}} F(\underline{x}) = \left[\frac{\partial F}{\partial x_1}, \frac{\partial F}{\partial x_2}, \dots, \frac{\partial F}{\partial x_n} \right]^T \quad \nabla_{\underline{x}}^2 F(\underline{x}) = \begin{bmatrix} \frac{\partial^2 F(\underline{x})}{\partial^2 x_1} & \frac{\partial^2 F(\underline{x})}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 F(\underline{x})}{\partial x_1 \partial x_n} \\ \frac{\partial^2 F(\underline{x})}{\partial x_2 \partial x_1} & \frac{\partial^2 F(\underline{x})}{\partial^2 x_2} & \dots & \frac{\partial^2 F(\underline{x})}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 F(\underline{x})}{\partial x_n \partial x_1} & \frac{\partial^2 F(\underline{x})}{\partial x_n \partial x_2} & \dots & \frac{\partial^2 F(\underline{x})}{\partial^2 x_n} \end{bmatrix}$$



مبانی بهینه سازی: مشتقات برداری جهت دار

- مشتق تابع F در مسیر بردار \underline{p} :

$$D_{\underline{p}} F(\underline{x}) = \frac{\underline{p}^T \nabla_{\underline{x}} F(\underline{x})}{\|\underline{p}\|}$$

- مشتق دوم تابع F در مسیر بردار \underline{p} :

$$D_{\underline{p}}^2 F(\underline{x}) = \frac{\underline{p}^T \nabla_{\underline{x}}^2 F(\underline{x}) \underline{p}}{\|\underline{p}\|^2}$$

- سوال:

در چه مسیرهایی مقدار مشتق برداری ماکزیمم، مینیمم یا صفر خواهد بود؟



مبانی بهینه سازی: شرایط لازم برای نقاط بهینه

- برای اینکه x^* نقطه مینیمم تابع F باشد

– شرط درجه اول :

$$\nabla_x F(x^*) = 0$$

نقاط ایستای تابع F

– شرط درجه دوم: (ماتریس مثبت معین)

$$\nabla_x^2 F(x^*) > 0$$

- شرط لازم برای نقطه مینیمم x^* :

$$\nabla_x F(x^*) = 0 \quad \nabla_x^2 F(x^*) \geq 0$$

- شرط لازم و کافی برای نقطه مینیمم x^* :

$$\nabla_x F(x^*) = 0 \quad \nabla_x^2 F(x^*) > 0$$

- شرط کافی برای اینکه x^* زین اسبی باشد، ماتریس هسیان نامعین باشد.



مبانی بهینه سازی: توابع درجه دوم

$$F(\underline{x}) = \frac{1}{2} \underline{x}^T A \underline{x} + \underline{b}^T \underline{x} + c, A^T = A$$

- متقارن بودن A الزامی نیست زیرا هر ماتریس نامتقارن را می توان به متقارن تبدیل کرد. چگونه؟

$$\nabla_{\underline{x}} F(\underline{x}) = \underline{b} + A \underline{x}$$

$$\nabla_{\underline{x}}^2 F(\underline{x}) = A$$

- شاخص عملکردی میانگین مربعات خطا از نوع درجه دوم می باشد.
- تمامی توابع با مشتقات پیوسته مرتبه دوم حول یک ناحیه به اندازه کافی کوچک مثل تابع درجه دوم عمل می کند. چرا؟
- بیشتر الگوریتمهای بهینه سازی با تابع عملکرد مرتبه دوم پس از تعداد محدودی تکرار به نقطه بهینه خواهند رسید.



مبانی بهینه سازی: توابع درجه دوم و ساختار ویژه

- در توابع درجه دوم ساختار ویژه (مقادیر و بردارهای ویژه) ماتریس هسیان نقش مهمی در مینیمم کردن توابع دارند.
- به علاوه مقادیر و بردارهای ویژه دارای **تعبیر فیزیکی** نیز هستند.

تمرین:

ارتباط مقادیر و بردارهای ویژه ماتریس هسیان در مینیمم سازی چیست؟ با توجه به نقشی که آنها در مثبت معین یا منفی معین کردن یک ماتریس دارند، توضیح دهید.
(در بخش ۷-۲-۸ کتاب آمده است.)



روند مینیمم سازی: الگوریتم کلی

- **روند بازگشتی:** تخمین جدید از روی تخمین فعلی قابل محاسبه است

$$\underline{x}(k+1) = \underline{x}(k) + \alpha(k) \underline{p}(k)$$

- $\underline{X}(k)$ تخمین فعلی نقطه مینیمم تابع F ، $\alpha(k)$ نرخ یادگیری و $\underline{p}(k)$ بردار جستجو است.

- در روشهای مختلف مینیمم سازی، بردار جستجو متفاوت است.
- $\underline{p}(k)$ به گونه ای تعیین می شود که مقدار تابع F در هر مرحله کاهش یابد.
- بردار جستجو از روی اطلاعات گرادیان و هسیان تابع محاسبه می شود.



روند مینیمم سازی: روش بیشترین نزول (SD)

- دیدیم که اگر مسیر $p(k)$ در خلاف جهت گرادیان باشد، مقدار مشتق جهتی کمترین میزان ممکن را خواهد داشت.
- در اینجا نیز با توجه به بسط تیلور تابع F حول $x(k)$ به سادگی دیده می شود که اگر **بردار جستجو** در **خلاف جهت گرادیان** انتخاب شود، بیشترین تنزل در مقدار تابع F را خواهیم داشت.
- **الگوریتم بیشترین نزول** برابر است با:

$$\underline{x}(k+1) = \underline{x}(k) - \alpha(k) \nabla F(\underline{x}(k))$$

- روش **تعیین نرخ یادگیری** $\alpha(k)$:
 - در نظر گرفتن یک **مقدار ثابت**. مثلاً ۰.۰۵ یا $\alpha(k) = 2/k$
 - یافتن $\alpha(k)$ در هر مرحله به گونه ای که تابع $F(x(k+1))$ نسبت به $\alpha(k)$ حداقل شود.
- نرخ یادگیری بهینه**



نکات مربوط به الگوریتم SD

- ثابت کنید نرخ یادگیری بهینه در الگوریتم SD برای توابع درجه دوم عبارتست از:
(بخش ۷-۳-۳ مطالعه شود)

$$\alpha_k = \frac{g_k^T g_k}{g_k^T A g_k}$$

- مراحل متوالی الگوریتم SD بر هم عمودند.