

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

شبکه کوانتیزاسیون برداری یادگیر

LVQ (*Learning Vector Quantization*)

Neural Networks

شبکه کوانتیزاسیون برداری یادگیر (LVQ)

○ توسط کوهونن (Kohonen)

Learning Vector Quantization (LVQ), is a prototype-based supervised classification algorithm.

○ روشی برای دسته‌بندی الگو


- هر واحد خروجی بیانگر دسته یا گروه خاصی از الگوها
- بردار وزن یک واحد خروجی = بردار مرجع (reference) یا کتاب کد (codebook) دسته‌ای که آن واحد نماینده آن است
- دسته‌بندی = نزدیک بودن بردار وزن یک واحد خروجی (بردار مرجع) به بردار ورودی
- تنظیم وزن‌ها با آموزش با نظارت

• ابتدا بردار وزن w_j را به بردار مرجع r_j می‌دهیم

• دسته‌بندی = بردار ورودی x را با بردار مرجع r_j (یا بردار وزن w_j) مقایسه می‌کنیم

ساختار شبکه کوانتیزاسیون برداری یادگیر (LVQ)

- مشابه نگاشت خودسازمانده کوهونن اما بدون در نظر گرفتن ساختار توپولوژیکی برای واحدهای خروجی
- هر واحد خروجی بیانگر یک دسته از داده‌ها



الگوریتم شبکه کوانتیزاسیون برداری یادگیر (LVQ)

- مرحله ۰ - به بردارهای مرجع (وزنها) و نرخ یادگیری مقدار اولیه دهید.
- مرحله ۱ - تا زمانی که شرایط توقف برقرار نیست، مراحل ۲ تا ۶ را انجام دهید.
- مرحله ۲ - برای هر بردار ورودی آموزش \mathbf{x} ، مراحل ۳ و ۴ را انجام دهید.
- مرحله ۳ - واحد J را به گونه‌ای پیدا کنید که $\|\mathbf{x} - \mathbf{w}_J\|$ کمینه باشد.
- مرحله ۴ - \mathbf{w}_J را به صورت زیر به روز کنید:

فاصله اقلیدسی

$$\mathbf{w}_J(\text{new}) = \mathbf{w}_J(\text{old}) + \alpha[\mathbf{x} - \mathbf{w}_J(\text{old})] \quad \text{اگر } T = C_J \text{ بود، آنگاه:}$$

دسته صحیح

دسته نام

$$\mathbf{w}_J(\text{new}) = \mathbf{w}_J(\text{old}) - \alpha[\mathbf{x} - \mathbf{w}_J(\text{old})] \quad \text{اگر } T \neq C_J \text{ بود، آنگاه:}$$

- مرحله ۵ - نرخ یادگیری را کاهش دهید.
- مرحله ۶ - شرایط توقف را بررسی کنید:
 - تعدادی ثابت تکرار یا کوچک شدن نرخ یادگیری تا یک مقدار مشخص

آموزش
بانظارت

مثال شبکه کوانتیزاسیون برداری یادگیر (LVQ)

VECTOR	CLASS
(1, 1, 0, 0)	1
(0, 0, 0, 1)	2
(0, 0, 1, 1)	2
(1, 0, 0, 0)	1
(0, 1, 1, 0)	2

○ مثال : پنج بردار در دو دسته ...

• مقداردهی اولیه وزن‌ها: استفاده از دو بردار آموزش

• مرحله ۰ - مقداردهی اولیه به وزن‌ها $w_1 = (1, 1, 0, 0)$ و $w_2 = (0, 0, 0, 1)$

مقداردهی اولیه به نرخ یادگیری $\alpha = 0.1$

• مرحله ۱ - آغاز محاسبات

• مرحله ۲ - برای بردار ورودی $x = (0, 0, 1, 1)$ با $T = 2$ ، مراحل ۳ و ۴ را انجام دهید.

• مرحله ۳ - واحد دوم برنده است، $J = 2$ ، چون x به w_2 نزدیک‌تر است.

• مرحله ۴ - چون $T = 2$ و $C_2 = 2$ ، w_2 را به صورت زیر به‌روز کنید:

$$w_2 = (0, 0, 0, 1) + 0.1[(0, 0, 1, 1) - (0, 0, 0, 1)] = (0, 0, 0.1, 1)$$

مثال شبکه کوانتیزاسیون برداری یادگیر (LVQ)

- مرحله ۲- برای بردار ورودی $\mathbf{x} = (1,0,0,0)$ با $T = 1$ ، مراحل ۳ و ۴ را انجام دهید.
- مرحله ۳- $J = 1$
- مرحله ۴- چون $T = 1$ و $C_1 = 1$ ، w_1 را به روز کنید:

$$w_1 = (1,1,0,0) + 0.1 [(1,0,0,0) - (1,1,0,0)] = (1, 0.9, 0, 0)$$

- مرحله ۲- برای بردار ورودی $\mathbf{x} = (0,1,1,0)$ با $T = 2$ ، مراحل ۳ و ۴ را انجام دهید.
- مرحله ۳- $J = 1$
- مرحله ۴- چون $T = 2$ ، اما $C_1 = 1$ ، w_1 را به صورت زیر به روز کنید:

$$w_1 = (1,0.9,0,0) - 0.1 [(0,1,1,0) - (1,0.9,0,0)] = (1, 0.89, -0.1, 0)$$

- مرحله ۵- در اینجا یک دور آموزش کامل می شود. نرخ یادگیری را کاهش دهید.
- مرحله ۶- شرایط توقف را بررسی کنید.

مرحله ۷- شرایط توقف را بررسی کنید.

مرحله ۸- در اینجا یک دور آموزش کامل می شود. نرخ یادگیری را کاهش دهید.

انواع دیگر شبکه کوانتیزاسیون برداری یادگیر (LVQ)

○ ایده

- در LVQ اصلی، فقط بردار مرجع که به بردار ورودی نزدیکتر است، به روز می‌شود.
 - مسیر حرکت الگوریتم به این بستگی دارد که آیا بردار مرجع برنده شده به همان دسته‌ای متعلق است که بردار ورودی تعلق دارد یا خیر.
- در الگوریتم‌های اصلاح شده، با در نظر گرفتن شرایطی، دو بردار (برنده اول و دوم) مجاز به یادگیری هستند.

○ سه روش دیگر: LVQ2, LVQ2.1 و LVQ3

انواع دیگر LVQ: LVQ2

○ شرایط تغییر هر دو بردار برنده اول و دوم

- واحد برنده اول و نفر دوم (دومین بردار نزدیک) دسته‌های مختلفی را نشان دهند.
- بردار ورودی و نفر دوم (دومین برنده) به یک دسته تعلق داشته باشند.
- فاصله برنده اول و بردار ورودی با فاصله بردار ورودی به نفر دوم تقریباً یکسان باشد.

فاصله ورودی تا بردار برنده

○ واقع شدن بردار ورودی در داخل یک پنجره: $\frac{d_c}{d_r} > 1 - \varepsilon$ و $\frac{d_r}{d_c} < 1 + \varepsilon$

فاصله ورودی تا دومین بردار برنده

پارامتر (وابسته به تعداد نمونه‌های آموزش) - مقدار نوعی ۰.۳۵

بردار مرجع برنده (عدم تعلق ورودی به آن)

$$y_c(t+1) = y_c(t) - \alpha(t)[x(t) - y_c(t)]$$

○ به روز کردن

بردار مرجع برنده دوم (تعلق ورودی به آن)

$$y_r(t+1) = y_r(t) + \alpha(t)[x(t) - y_r(t)]$$

انواع دیگر LVQ: LVQ2.1

○ مشابه LVQ2

- در نظر گرفتن دو بردار مرجع نزدیک تر برای به روز کردن
- شرط به روز کردن (تفاوت با LVQ2) یکی از این دو بردار، به دسته صحیح (دسته ای که بردار ورودی به آن تعلق دارد) تعلق داشته باشد و دیگری به این دسته صحیح تعلق نداشته باشد.

○ در LVQ2، شرط به روز کردن = بردار ورودی متعلق به دومین برنده است

- همانند LVQ2، شرط به روز کردن قرار گرفتن ورودی درون یک پنجره است:

فاصله ورودی تا بردار برنده اول

$$\max \left[\frac{d_{c1}}{d_{c2}}, \frac{d_{c2}}{d_{c1}} \right] < 1 + \varepsilon \quad \text{و} \quad \min \left[\frac{d_{c1}}{d_{c2}}, \frac{d_{c2}}{d_{c1}} \right] > 1 - \varepsilon$$

فاصله ورودی تا دومین بردار برنده

○ به روز کردن

- ورودی متعلق به دسته (می تواند $c1$ یا $c2$ باشد) $y_{c1}(t+1) = y_{c1}(t) + \alpha(t) [\mathbf{x}(t) - y_{c1}(t)]$
- عدم تعلق ورودی به دسته (می تواند $c1$ یا $c2$ باشد) $y_{c2}(t+1) = y_{c2}(t) - \alpha(t) [\mathbf{x}(t) - y_{c2}(t)]$

انواع دیگر LVQ: LVQ3

مقدار = ۰.۲

$$\min \left[\frac{d_{c1}}{d_{c2}}, \frac{d_{c2}}{d_{c1}} \right] > (1 - \varepsilon)(1 + \varepsilon)$$

○ پنجره

• اجازه یادگیری به دو بردار نزدیکتر به بردار ورودی

○ بردار ورودی فقط با یکی از دو بردار برنده در یک دسته باشند

• به روز کردن مشابه LVQ2.1

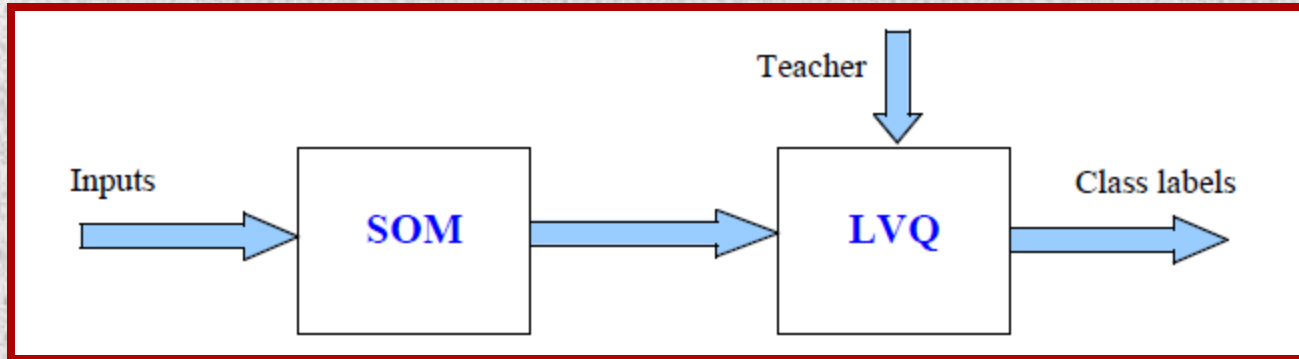
○ بردار ورودی، دو بردار برنده در یک دسته باشند (تفاوت با LVQ2.1)

• به روز شدن هر دو بردار برنده

$$\mathbf{y}_c(t+1) = \mathbf{y}_c(t) + \beta(t) [\mathbf{x}(t) - \mathbf{y}_c(t)]$$

$$\beta(t) = m \alpha(t) \quad 0,1 < m < 0,5$$

شبکه کوانتیزاسیون برداری یادگیر (LVQ)



This is particularly useful for *pattern classification* problems. The first step is feature selection – the unsupervised identification of a reasonably small set of features in which the essential information content of the input data is concentrated. The second step is the classification where the feature domains are assigned to individual classes.
