


Глубокие нейронные сети
Функция потерь на основе
перекрестной энтропии
(Cross-entropy cost function)


Лекция 5

Проблема с замедлением обучения (исчезающий градиент)

$$V = \{(1; 0)\}$$





Обученный нейрон



Зависимость скорости обучения от начальных значений w и b

$$\eta = 0.15$$

Правильный ответ: 0.0025



Начальные значения:

$$w = 0.6$$

$$b = 0.9$$

Начальные значения:

$$w = 2$$

$$b = 2$$

Анализ проблемы

$$C = \frac{(y - a)^2}{2}$$

$$a = \sigma(z); z = wx + b; \mathbf{x = 1; y = 0}$$

$$\frac{\partial C}{\partial w} = \frac{\partial C}{\partial a} \cdot \frac{\partial \sigma(z)}{\partial z} \cdot \frac{\partial z}{\partial w} = (a - y)\sigma'(z)x = a\sigma'(z) \cdot 1$$

$$\frac{\partial C}{\partial b} = \frac{\partial C}{\partial a} \cdot \frac{\partial \sigma(z)}{\partial z} \cdot \frac{\partial z}{\partial b} = (a - y)\sigma'(z) = a\sigma'(z)$$

© Соколинский Л.Б. Глубокие нейронные сети 14.10.2023

Цепное правило

Пусть f зависит от g , а g зависит от x . Тогда

$$\frac{\partial f}{\partial x} = \frac{\partial f}{\partial g} \cdot \frac{\partial g}{\partial x}$$

5. Функция потерь на основе перекрестной энтропии 22

Продолжение анализа проблемы


$$\left. \begin{aligned} w &:= w - \eta \frac{\partial C}{\partial w} \\ b &:= b - \eta \frac{\partial C}{\partial b} \end{aligned} \right\} \Rightarrow \begin{cases} w := w - \eta a \sigma'(z) \\ b := b - \eta a \sigma'(z) \end{cases}$$

$$\lim_{z \rightarrow +\infty} \sigma'(z) = 0$$

$$\lim_{z \rightarrow -\infty} \sigma'(z) = 0$$




Зависимость скорости обучения от начальных значений w и b



Выводы

- Если выходной сигнал нейрона близок к нулю или единице, то значение производной для сигмоидной функции близко к нулю
- Следовательно, в этих случаях будет наблюдаться замедление обучения
- Что делать?
- **Решение:** заменить среднеквадратичную функцию потерь на функцию *перекрестной энтропии* (при условии, что выходными сигналами могут быть только значения из множества $\{0,1\}$)

Использование функции перекрестной энтропии в качестве функции потерь



$$z = b + \sum_{i=1}^n w_i x_i$$


$$C = -(y \ln a + (1 - y) \ln(1 - a))$$

Проверка ограничения $C \geq 0$

$$C = y(-\ln a) + (1 - y)(-\ln(1 - a))$$

$$a = \sigma(z) \Rightarrow 0 < a < 1 \Rightarrow \ln a < 0 \wedge \ln(1 - a) < 0 \left. \vphantom{a = \sigma(z)} \right\} \Rightarrow C \geq 0$$

$$0 \leq y \leq 1$$



Свойства функции потерь на основе перекрестной энтропии

$$C = -(y \ln a + (1 - y) \ln(1 - a))$$

$$\lim_{a \rightarrow y} C = 0$$

(1)

Если выходной сигнал близок желаемому, величина функции потерь близка к нулю

$$\frac{\partial C}{\partial w_i} = x_i \cdot (\sigma(z) - y)$$

(2)

$$\frac{\partial C}{\partial b} = \sigma(z) - y$$

(3)

Нет замедления обучения при $\sigma'(z) \rightarrow 0$

Доказательство $\lim_{a \rightarrow y} C = 0$ (1)

$$C = -(y \ln a + (1 - y) \ln(1 - a))$$

$$y = 0 \approx a \Rightarrow \begin{cases} y \ln a = 0 \\ (1 - y) \ln(1 - a) = \ln(1 - a) \approx \ln 1 = 0 \end{cases} \Rightarrow \\ \Rightarrow C \approx 0$$

$$y = 1 \approx a \Rightarrow \begin{cases} y \ln a = \ln a \approx \ln 1 = 0 \\ (1 - y) \ln(1 - a) = 0 \end{cases} \\ \Rightarrow C \approx 0$$

© Соколинский Л.Б. Глубокие нейронные сети 14.10.2023

Примерно равно: \approx

$$x \approx h \Rightarrow y \approx g$$

$$\Updownarrow$$

$$\lim_{x \rightarrow h} y = g$$

5. Функция потерь на основе перекрестной энтропии 24

Доказательство $\frac{\partial C}{\partial w_i} = x_i \cdot (\sigma(z) - y) \quad (2)$

$$C = -(y \ln a + (1 - y) \ln(1 - a))$$

$$\frac{\partial C}{\partial w_i} = \frac{\partial C}{\partial a} \cdot \frac{\partial a}{\partial z} \cdot \frac{\partial z}{\partial w_i} = - \left(\frac{y}{a} - \frac{1-y}{1-a} \right) \cdot \frac{\partial a}{\partial z} \cdot \frac{\partial z}{\partial w_i} =$$

$$= - \left(\frac{y}{\sigma(z)} - \frac{1-y}{1-\sigma(z)} \right) \cdot \sigma'(z) \cdot \frac{\partial z}{\partial w_i} =$$

$$= - \left(\frac{y}{\sigma(z)} - \frac{1-y}{1-\sigma(z)} \right) \cdot \sigma'(z) \cdot x_i =$$

$$= - \frac{\sigma'(z) \cdot x_i}{\sigma(z)(1-\sigma(z))} (y - \sigma(z)) \cdot x_i =$$

$$= -x_i \cdot (y - \sigma(z)) = x_i \cdot (\sigma(z) - y)$$

Цепное правило

Пусть f зависит от g , а g зависит от x . Тогда

$$\frac{\partial f}{\partial x} = \frac{\partial f}{\partial g} \cdot \frac{\partial g}{\partial x}$$

Использование функции перекрестной энтропии в качестве функции потерь

$z = b + \sum_{i=1}^n w_i x_i$

$a = \sigma(z)$

$$C = -(y \ln a + (1 - y) \ln(1 - a))$$

Лемма: $\sigma'(z) = \sigma(z)(1 - \sigma(z))$

$$\sigma'(z) = \frac{e^{-z}}{(1+e^{-z})^2} =$$

$$= \frac{1}{1+e^{-z}} \cdot \frac{1+e^{-z}-1}{1+e^{-z}} = \frac{1}{1+e^{-z}} \cdot \left(\frac{1+e^{-z}}{1+e^{-z}} - \frac{1}{1+e^{-z}} \right) =$$

$$= \sigma(z)(1 - \sigma(z))$$

Доказательство $\frac{\partial C}{\partial b} = \sigma(z) - y$ (3)

$$C = -(y \ln a + (1 - y) \ln(1 - a))$$

$$\frac{\partial C}{\partial b} = \frac{\partial C}{\partial a} \cdot \frac{\partial a}{\partial z} \cdot \frac{\partial z}{\partial b} = - \left(\frac{y}{a} - \frac{1-y}{1-a} \right) \cdot \frac{\partial a}{\partial z} \cdot \frac{\partial z}{\partial b} =$$

$$= - \left(\frac{y}{\sigma(z)} - \frac{1-y}{1-\sigma(z)} \right) \cdot \sigma'(z) \cdot \frac{\partial z}{\partial b} =$$

$$= - \left(\frac{y}{\sigma(z)} - \frac{1-y}{1-\sigma(z)} \right) \cdot \sigma'(z) \cdot 1 =$$

$$= - \frac{\sigma'(z)}{\sigma(z)(1-\sigma(z))} (y - \sigma(z)) =$$

$$= -(y - \sigma(z)) = \sigma(z) - y$$


Цепное правило

Пусть f зависит от g , а g зависит от x . Тогда

$$\frac{\partial f}{\partial x} = \frac{\partial f}{\partial g} \cdot \frac{\partial g}{\partial x}$$

3. Функция потерь на основе перекрестной энтропии

Использование функции перекрестной энтропии в качестве функции потерь



$z = b + \sum_{i=1}^n w_i x_i$

$C = -(y \ln a + (1 - y) \ln(1 - a))$

3. Функция потерь на основе перекрестной энтропии

Лемма: $\sigma'(z) = \sigma(z)(1 - \sigma(z))$

$$\sigma'(z) = \frac{e^{-z}}{(1+e^{-z})^2} =$$

$$= \frac{1}{1+e^{-z}} \cdot \frac{1+e^{-z}-1}{1+e^{-z}} = \frac{1}{1+e^{-z}} \cdot \left(\frac{1+e^{-z}}{1+e^{-z}} - \frac{1}{1+e^{-z}} \right) =$$



$$= \sigma(z)(1 - \sigma(z))$$

3. Функция потерь на основе перекрестной энтропии

Эффект от применения функции перекрестной энтропии

$$\eta = 0.005$$

Правильный ответ: 0.0025



Начальные значения:

$$w = 0.6$$

$$b = 0.9$$

Начальные значения:

$$w = 2$$

$$b = 2$$

Обобщение функции потерь для нейронной сети с несколькими выходами

$$C = - \sum_j \left(y_j \ln a_j^{(L)} + (1 - y_j) \ln (1 - a_j^{(L)}) \right)$$

Обобщение функции потерь на всю обучающую выборку

$$\mathbb{C} = -\frac{1}{|V|} \sum_{(x,y) \in V} \sum_j \left(y_j \ln a_j^{(L)} + (1 - y_j) \ln (1 - a_j^{(L)}) \right)$$

Вычисление меры $\delta_i^{(L)}$ влияния нейрона на величину ошибки для выходного слоя

$$\begin{aligned} \delta_i^{(L)} &= \frac{\partial C}{\partial z_i^{(L)}} = \frac{\partial C}{\partial a_i^L} \cdot \frac{\partial a_i^{(L)}}{\partial z_i^L} = - \left(\frac{y_i}{a_i^L} - \frac{1-y_i}{1-a_i^L} \right) \cdot \frac{\partial a_i^{(L)}}{\partial z_i^{(L)}} = \\ &= - \left(\frac{y_i}{\sigma(z_i^{(L)})} - \frac{1-y_i}{1-\sigma(z_i^{(L)})} \right) \cdot \sigma'(z_i^{(L)}) = \\ &= - \frac{y_i - \sigma(z_i^{(L)})}{\sigma(z_i^{(L)}) \cdot (1-\sigma(z_i^{(L)}))} \cdot \sigma'(z_i^{(L)}) = \\ &= - \frac{y_i - \sigma(z_i^{(L)})}{\sigma(z_i^{(L)}) \cdot (1-\sigma(z_i^{(L)}))} \cdot \sigma(z_i^{(L)}) \left(1 - \sigma(z_i^{(L)}) \right) = \\ &= - \left(y_i - \sigma(z_i^{(L)}) \right) = \sigma(z_i^{(L)}) - y_i = a_i^{(L)} - y_i \end{aligned}$$

Обобщение функции потерь для нейронной сети с несколькими выходами

$$C = - \sum_j (y_j \ln a_j^{(L)} + (1 - y_j) \ln (1 - a_j^{(L)}))$$

Цепное правило

Пусть f зависит от g , а g зависит от x . Тогда

$$\frac{\partial f}{\partial x} = \frac{\partial f}{\partial g} \cdot \frac{\partial g}{\partial x}$$

Лемма: $\sigma'(z) = \sigma(z)(1 - \sigma(z))$

$$\begin{aligned} \sigma'(z) &= \frac{e^{-z}}{(1+e^{-z})^2} = \\ &= \frac{1}{1+e^{-z}} \cdot \frac{1+e^{-z}-1}{1+e^{-z}} = \frac{1}{1+e^{-z}} \cdot \left(\frac{1+e^{-z}}{1+e^{-z}} - \frac{1}{1+e^{-z}} \right) = \\ &= \sigma(z)(1 - \sigma(z)) \end{aligned}$$

Формулы обратного распространения ошибки

Среднеквадратичная ошибка	Перекрестная энтропия	
$\delta_i^{(L)} = (a_i^{(L)} - y_i) \cdot \sigma'(z_i^{(L)})$	$\delta_i^{(L)} = a_i^{(L)} - y_i$	BP1
$\delta_j^{(l)} = \sigma'(z_j^{(l)}) \sum_i w_{ji}^{(l+1)} \delta_i^{(l+1)}$		BP2
$\frac{\partial C}{\partial b_i^{(l)}} = \delta_i^{(l)}$		BP3
$\frac{\partial C}{\partial w_{ji}^{(l)}} = \delta_i^{(l)} \cdot a_j^{(l-1)}$		BP4

Отличительные свойства перекрестной энтропии

1. Ориентирована на нейронные сети с выходными сигналами из множества $\{0,1\}$
2. Не приводит к замедлению обучения при $\sigma \left(z_i^{(L)} \right) \rightarrow 0$
3. Не приводит к замедлению обучения при $\sigma \left(z_i^{(L)} \right) \rightarrow 1$

Конец лекции 5

Лемма: $\sigma'(z) = \sigma(z)(1 - \sigma(z))$

$$\sigma'(z) = \frac{e^{-z}}{(1+e^{-z})^2} =$$

$$= \frac{1}{1+e^{-z}} \cdot \frac{1+e^{-z}-1}{1+e^{-z}} = \frac{1}{1+e^{-z}} \cdot \left(\frac{1+e^{-z}}{1+e^{-z}} - \frac{1}{1+e^{-z}} \right) =$$


$$= \sigma(z)(1 - \sigma(z))$$

Цепное правило

Пусть f зависит от g , а g зависит от x . Тогда

$$\frac{\partial f}{\partial x} = \frac{\partial f}{\partial g} \cdot \frac{\partial g}{\partial x}$$

Натуральный логарифм

$$y = \ln x$$


Примерно равно: \approx

$$x \approx h \Rightarrow y \approx g$$



$$\lim_{x \rightarrow h} y = g$$

Сигмоидная (логистическая) функция

- Область определения: \mathbb{R}
- Множество значений: $(0;1)$

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

