

Машинно обучение

Лабораторно упражнение 8

Обучение на невронна мрежа чрез Backpropagation алгоритъм

Упражнението демонстрира обучение на невронна мрежа чрез алгоритъм backpropagation. Целта е да се намерят такива стойности на параметрите (теглата на връзките) в мрежата, при които функцията на цената, оценяваща точността на мрежата, има минимална стойност.

Като пример се разглежда задачата за разпознаване на ръкописни цифри от 0 до 9.

1. Обучителни данни

Файлът data.mat съдържа 5000 форматирани изображения на ръкописни цифри от 0 до 9. Данните са взети от еталонната база данни MNIST (<http://yann.lecun.com/exdb/mnist/>), съдържаща множество примери за ръкописни цифри. Файлът е в .mat формат, т.е. данните са записани в MATLAB матрична форма вместо в текстов ASCII формат. Изображението на всяка цифра се представя с матрица, която се зарежда директно в програмата.

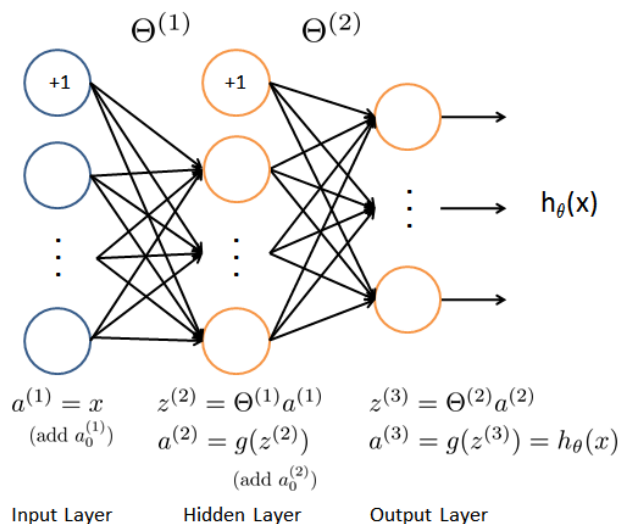
Във файла са дадени 5000 обучителни примери, всеки от които е изображение, представено с матрица от пиксели 28x28. Всеки пиксел е представен с числова стойност за неговия интензитет от сивата скала. Матрицата 28x28 се преобразува във вектор 784x1. Като резултат всеки обучителен пример става един ред в матрицата X. Тя има размер 5000 x 784 и всеки ред в нея и обучителен пример с изображение на ръкописна цифра.

Обучителните примери съдържат също вектор y (5000x1) с етикети labels) за всяка цифра.

2. Невронна мрежа

2.1. Модел на мрежата

Мрежата се състои от 3 слоя - входен слой (input layer), скрит слой (hidden layer) и изходен слой (output layer) (фиг. 1). Входните данни са стойностите на интензитетите на пикселите от изображението на цифра. Тъй като изображенията са с размерност 28x28, входният слой има 784 върха (+1 за допълнителен връх за т.нар. отклонение (bias unit)).



Фиг. 1. Модел на невронна мрежа за разпознаване на ръкописни цифри

$\theta^{(1)}$ - матрица със стойности на параметри в първия слой (input layer)

$\theta^{(2)}$ - матрица със стойности на параметри в скрития слой (hidden layer)

$\theta^{(1)}$ се зарежда в Theta1 с размерност 25x401, а $\theta^{(2)}$ се зарежда в Theta2 с размерност 10x26. Тези размерности са определени от това, че във втория (скрития слой) слой има 25 върха, а в изходния слой има 10 върха (по един за всеки възможен клас).

Файлът weights.mat съдържа стойности на предварително обучени параметри.

2.2. Feedforward Propagation и функция на цената (cost function)

Feedforward propagation е алгоритъм за изчисляване на стойностите във върховете от всеки слой на невронната мрежа. В дадената невронна мрежа стойностите във върховете се изчисляват по следния начин:

За първи слой (input layer):

Добавяме връх $a_0^{(1)} = 1$.

$$a^{(1)} = X$$

, където

$a^{(1)}$ - стойности на върховете на мрежата в първия слой

X - матрица със стойности на входните променливи

За втори слой (hidden layer)

Добавяме връх $a_0^{(2)} = 1$.

$$z^{(2)} = \theta^{(1)}a^{(1)}$$

$$a^{(2)} = g(z^{(2)})$$

$\theta^{(1)}$ - стойности на параметрите в първи слой на мрежата

$a^{(1)}$ - стойности на върховете в първи слой на мрежата

$g(z^{(2)})$ - сигмоидна функция с параметър $z^{(2)}$

За трети слой (output layer)

$$z^{(3)} = \theta^{(2)}a^{(2)}$$

$$a^{(3)} = g(z^{(3)}) = h_{\theta}(x)$$

$\theta^{(2)}$ - стойности на параметрите във втори слой на мрежата

$a^{(2)}$ - стойности на върховете във втори слой на мрежата

$g(z^{(3)})$ - сигмоидна функция с параметър $z^{(3)}$

Стойността на хипотезата $h_{\theta}(x)$ се получава в изходния слой на мрежата като стойност в интервала 0-1 за всеки възможен клас. Тази стойност определя вероятността за принадлежност на входните данни към дадения клас. Крайният резултат от невронната мрежа е класът с най-голяма стойност на хипотезата, т.е. класът с най-голяма вероятност.

Функцията на цената се изчислява по следния начин:

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m \sum_{k=1}^K \left[-y_k^{(i)} \log((h_{\theta}(x^{(i)}))_k) - (1 - y_k^{(i)}) \log(1 - (h_{\theta}(x^{(i)}))_k) \right] + \frac{\lambda}{2m} \left[\sum_{j=1}^{25} \sum_{k=1}^{400} (\theta_{j,k}^{(1)})^2 + \sum_{j=1}^{10} \sum_{k=1}^{25} (\theta_{j,k}^{(2)})^2 \right]$$

, където $h_{\theta}(x)$ се изчислява, както е показано на фиг. 1, а $K=10$ - общ брой на възможните класове. Обърнете внимание, че:

- $h_{\theta}(x^{(i)})_k = a_k^{(3)}$ е изходната стойност във връх k от изходния слой;
- Докато оригиналните класове имат стойности 1,2,3,...,10, записани в y , то за обучението на невронната мрежа е необходимо тези стойности да бъдат представени като вектори, съставени само от 0 и 1, т.е.

$$y = \begin{bmatrix} 1 \\ 0 \\ 0 \\ \dots \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 1 \\ 0 \\ \dots \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \\ 1 \\ \dots \\ 0 \end{bmatrix} \dots \begin{bmatrix} 0 \\ 0 \\ 0 \\ \dots \\ 1 \end{bmatrix}$$

Напр., ако $x^{(i)}$ е изображение на цифрата 5, то съответстващият вектор $y^{(i)}$, използван във функцията на цената, е 10-разреден вектор с $y_5 = 1$ и 0 в останалите позиции.


2. Алгоритъм Back propagation

2.1. Градиент на сигмоидната функция

Градиентът на сигмоидната функция се изчислява по следния начин:

$$g'(z) = \frac{d}{dz} g(z) = g(z)(1 - g(z)), \text{ където } sigmoid(z) = g(z) = \frac{1}{1+e^{-z}}$$

2.2. Back propagation



Фиг. 2. Алгоритъм Back propagation

За всеки обучителен пример $(x^{(t)}, y^{(t)})$ изпълняваме forward propagation за изчисляване на стойностите във върховете до получаване на стойността на хипотезата $h_{\theta}(x)$ в изходния слой. След това за всеки връх j в слой l изчисляваме „грешка“ $\delta_j^{(l)}$, която измерва доколко даден връх е отговорен за крайната грешка в изхода на мрежата.

За върховете в изходния слой можем директно да изчислим грешката $\delta_j^{(3)}$ чрез стойността y от обучителните примери (слой 3 е изходен). За върховете в скрития слой грешката $\delta_j^{(l)}$ се изчислява чрез усреднената грешка в слой $(l+1)$.

Стъпки на Back propagation алгоритъма:

1. На стойностите на върховете $a^{(1)}$ във входния слой присвояваме стойностите от $t^{\text{ти}}$ обучителен пример $x^{(t)}$. След това изпълняваме feedforward за изчисляване на стойностите $z^{(2)}, a^{(2)}, z^{(3)}, a^{(3)}$ в слоеве 2 и 3.

2. За всеки връх k в слой 3 (изходен слой) изчисляваме грешката

$$\delta_k^{(3)} = (a_k^{(3)} - y_k)$$

, където $y_k \in \{0,1\}$ определя дали поредният обучителен пример принадлежи на клас k ($y_k = 1$) или не ($y_k = 0$).

3. За скрития слой $l=2$ изчисляваме грешката

$$\delta^{(2)} = (\theta^{(2)})^T \delta^{(3)} * g'(z^{(2)})$$

4. Изчисляваме градиента за поредния обучителен пример

$$\Delta^{(l)} = \Delta^{(l)} + \delta^{(l+1)} (a^{(l)})^T$$

5. Изчисляваме регуляризирания градиент

$$\frac{\partial}{\partial \theta_{ij}^{(l)}} J(\theta) = D_{ij}^{(l)} := \frac{1}{m} \Delta_{ij}^{(l)} \text{ при } j = 0$$

$$\frac{\partial}{\partial \theta_{ij}^{(l)}} J(\theta) = D_{ij}^{(l)} := \frac{1}{m} (\Delta_{ij}^{(l)} + \lambda \theta_{ij}^{(l)}) \text{ при } j \geq 1$$

Задача 1. Довършете функцията `sigmoidGradient(z)`.

Задача 2. Във функцията `nnCostFunction` довършете изчисляването на `a1, z2, z3, a3` (feedforward propagation).

Задача 3. Във функцията `nnCostFunction` довършете изчисляването на `d3, delta1, delta2, theta1_grad, theta2_grad` (back propagation).

Изпълнете скрипта. Би трябвало да получите, че стойността на цената без регуляризация е около 0.287629165161, а с регуляризация - около 0.383769859091.

Задача 5. Изпълнете функцията `sigmoidGradient` последователно с параметри -1, -0.5, 0, 0.5, 1.

Резултат:

Сигмоид градиент

0.196611933241

0.235003712202

0.25

0.235003712202

0.196611933241