

Rezolvarea problemelor cu ajutorul metodelor de învățare



Obiective

Dezvoltarea sistemelor care învăță singure. Algoritmi de învățare. Specificarea, proiectarea și implementarea sistemelor care învăță singure cum să rezolve probleme de clasificare.



Aspecte teoretice

Proiectarea și dezvoltarea sistemelor care învăță singure.

Algoritmi de învățare de tipul:

- *stochastic gradient descent*
-



Probleme abordate

1. Scurta prezentare a problemei
 - a. ce se da (input X, output Y, un input xnou), ce se cere (functia care transforma X in Y: $f(X) = Y$, astfel incat sa poata fi calculat $ynou=f(xnou)$)
 - b. ce poate fi X ? -->
 - i. o lista de valori numerice (regresie simpla) $X = (x_1), x_1 = x_{11}, x_{21}, \dots, x_{n1}$, unde n e nr de exemple de antrenare,
 - ii. vector cu mai multe dimensiuni de valori numerice (regresie multipla): daca avem 2 dimensiuni: $X = (x_1, x_2), x_1 = (x_{11}, x_{21}, \dots, x_{n1}), x_2 = (x_{12}, x_{22}, x_{32}, \dots, x_{n2})$, unde n e nr de exemple de antrenare
 - c. ce poate fi Y? -->
 - i. o lista de etichete (pt un exemplu, trebuie prezis un singur output), $Y = (y_1), y_1 = y_{11}, y_{21}, \dots, y_{n1}$, unde n e nr de exemple de antrenare,
 - ii. vector cu mai multe dimensiuni de etichete: daca avem 3 dimensiuni: $Y = (y_1, y_2, y_3), y_1 = (y_{11}, y_{21}, \dots, y_{n1}), y_2 = (y_{12}, y_{22}, y_{32}, \dots, y_{n2}), y_3 = (y_{13}, y_{23}, \dots, y_{n3})$, unde n e nr de exemple de antrenare (pt un exemplu, trebuie prezise mai multe (3) output-uri/etichete)
2. Metode de identificare a functiei f pt cazul in care f este functie liniara, $X = (x_i)_{i=1,n}, x_i = (x_{i,1})$ - un exemplu are un singur atribut, $Y = (y_i)_{i=1,n}, y_i = (y_{i,1})$ - un exemplu are un singur output eticheta
 - a. gradient descent - regresie logistică

Presupunem tot un model liniar de clasificare

$$f(x) = a_0 + a_1 x_1 + a_2 x_2 + a_3 x_3 + \dots$$

Scopul este gasirea acelor coeficienti $a = (a_0, a_1, a_2, \dots)$ care maximizeaza probabilitatea clasificarii corecte. Putem presupune ca avem clasificare binara (clasa pozitiva si clasa negativa)

X sunt numere reale, deci $f(x)$ va fi un nr real. Putem asocia fiecarui exemplu x o probabilitate (probabilitatea ca exemplul curent sa apartina clasei pozitive):

$P_{poz}(x) = 1 / (1 + \exp(-x))$ - o functie sigmoid (care este convexa, deci putem sa ii gasim optimul global); dar putem alege si alta functie care sa modeleze probabilitatea

Fiind dat $P_{poz}(x)$, putem calcula probabilitatea ca un exemplu să apartină clasei negative:
 $P_{neg}(x) = 1 - P_{poz}(x)$

Clasificarea va fi cu atât mai bună cu cat probabilitatile asociate tuturor exemplelor (în număr de n) sunt mai apropiate de 1, adică putem maximiza

$$\begin{aligned} \max \prod_{i=1}^n P(x^i) &= \max \left(\prod_{i=1}^n P_{poz}(x^i) \prod_{i=1}^n P_{neg}(x^i) \right) \\ &= \max \left(\prod_{i=1}^n P_{poz}(x^i) \prod_{i=1}^n (1 - P_{poz}(x^i)) \right) \\ &= \min - \left(\prod_{i=1}^n P_{poz}(x^i) \prod_{i=1}^n (1 - P_{poz}(x^i)) \right) \\ &= \min - \left(\prod_{i=1}^n h(x^i) \prod_{i=1}^n (1 - h(x^i)) \right) \end{aligned}$$

Prin logaritmarea expresiei de mai sus, produsul se transformă în suma și se poate obține expresia:

$$E = - \sum_{y^i=1 \text{ (clasa pozitiva)}} y^i \log(h(x^i)) - \sum_{y^i=0 \text{ (clasa negativă)}} (1 - y^i) \log(1 - h(x^i))$$

Pentru a se găsi punctul de optim al acestei expresii, trebuie calculate derivatele parțiale (în funcție de coeficienții a_0, a_1, a_2, \dots)

Se folosesc formulele de derivare:

$$'(\log(x)) = 1/x$$

$$g(z) = 1 / (1 + \exp(-z)), g'(z) = \exp(-z) / (1 + \exp(-z))^2 = 1 / (1 + \exp(-z)) * (1 - 1 / (1 + \exp(-z))) = g(z) * (1 - g(z))$$

$$f(x) = a_0 + a_1 x_1 + a_2 x_2 + \dots$$

$$\delta f / \delta a_0 = 1$$

$$\delta f / \delta a_1 = x_1$$

$$\delta f / \delta a_2 = x_2$$

$$h(x) = \text{sigm}(f(x)) = 1 / (1 + \exp(-a_0 - a_1 x_1 - a_2 x_2 - \dots))$$

$$\begin{aligned}
\frac{\partial E}{\partial a_0} &= - \sum_{i=1}^n \left(\frac{y^i}{h(x^i)} + \frac{1-y^i}{1-h(x^i)} \right) \frac{\partial h(x^i)}{\partial a_0} \\
&= - \sum_{i=1}^n \left(\frac{y^i h(x^i) (1-h(x^i))}{h(x^i)} + \frac{(1-y^i) h(x^i) (1-h(x^i))}{1-h(x^i)} \right) \frac{\partial f(x^i)}{\partial a_0} \\
&= - \sum_{i=1}^n \left(\frac{y^i h(x^i) (1-h(x^i))}{h(x^i)} + \frac{(1-y^i) h(x^i) (1-h(x^i))}{1-h(x^i)} \right) * 1 \\
&= - \sum_{i=1}^n \left(\frac{y^i h(x^i) (1-h(x^i))^2 + (1-y^i) h^2(x^i) (1-h(x^i))}{h(x^i) (1-h(x^i))} \right) \\
&= - \sum_{i=1}^n \left(\frac{h(x^i) (1-h(x^i)) [y^i * (1-h(x^i)) + (1-y^i) h(x^i)]}{h(x^i) (1-h(x^i))} \right) \\
&= - \sum_{i=1}^n ([y^i * (1-h(x^i)) + (1-y^i) h(x^i)]) = - \sum_{i=1}^n (y^i - h(x^i)) \\
&= \sum_{i=1}^n (h(x^i) - y^i)
\end{aligned}$$

Similar

$$\begin{aligned}
\frac{\partial E}{\partial a_1} &= \sum_{i=1}^n (h(x^i) - y^i) x_1^i \\
\frac{\partial E}{\partial a_2} &= \sum_{i=1}^n (h(x^i) - y^i) x_2^i
\end{aligned}$$

Functia de cost E este convexa, deci putem sa ii gasim punctul de optim cu metoda gradientului: pornim cu coeficienti a0,a1,a2 random si ii imbunatatim pe baza formulei

$$a_i = a_i - learninRate * \frac{\partial E}{\partial a_i}$$

1. scalarea lui f la intervalul (0,1) - se poate cu ajutorul unei functii sigmoid sigmoid(z) = 1 / (1 + exp(0 - z))
 2. discretizarea intervalului
 - a. pt clasificare binara (2 etichete) fixarea unui prag (De ex Theta = 0.5) astfel încât f(x) sub Theta va însemna eticheta 1, iar f(x) peste prag va însemna eticheta 2
 - b. pt clasificare cu mai multe clase se pot fixa mai multe praguri (nr de praguri = nr de clase - 1)
 3. Exemplu de problema
- Enunt**

Se cunosc următoarele n (n = 5) informații aferente unei anumite perioade de timp: numărul de minute însozite dintr-o zi, nr de meciuri dintr-o zi și cantitatea de bere consumată pe o terasă.

Nr exemplu	Nr ore însozite (x_1)	Nr meciuri	Nr beri (Y)
i = 1	120	2	Mica
i = 2	180	1	Mica
i = 3	300	4	Mare
i = 4	420	6	Mare
i = 5	540	5	Mare

Să se aproximeze (folosind un model liniar multiplu) câte beri se vor consuma într-o zi cu 240 minute însozite și 3 meciuri.

Rezolvare:

1. Normalizarea datelor

$$\text{valNormalizat} = \frac{\text{val} - \text{medie}}{\text{deviația standard}} \quad (1)$$

Medie = suma valorilor / nr de valori

Deviația¹ = $\sqrt{\text{sumă patratelor diferențelor (valoare - medie)}} / (\text{nr valori} - 1)$

Nr exemplu	Nr ore însozite (x_1)	Nr meciuri (x_2)	Nr beri (Y)
i = 1	120	2	Mica
i = 2	180	1	Mica
i = 3	300	4	Mare
i = 4	420	6	Mare
i = 5	540	5	Mare
Media	312	5.6	
Deviația	171.81	2.07	

$$\text{Media } x_1 = (120 + 180 + 300 + 420 + 540) / 5 = 312$$

$$\text{Media } x_2 = (2 + 1 + 4 + 6 + 5) / 5 = 3.6$$

$$\text{Deviația } x_1 = \sqrt{((120 - 312)^2 + (180 - 312)^2 + (300 - 312)^2 + (420 - 312)^2 + (540 - 312)^2) / (5 - 1)} = 171.81$$

$$\text{Deviația } x_2 = \sqrt{(2 - 3.6)^2 + (1 - 3.6)^2 + (4 - 3.6)^2 + (6 - 3.6)^2 + (5 - 3.6)^2} / (5 - 1) = 2.07$$

Valorile normalize

$$x_1 \text{ pt } i=1 : (120 - 312) / 171.81 = -1.11$$

Nr exemplu	Nr ore însozite (x_1)	Nr meciuri (x_2)	Nr beri (Y)
i = 1	120	2	Mica

¹ la nivel de eșantion (de aceea e cu n - 1 la numitor)

i = 1	-1.11749	-0.77159	Mica
i = 2	-0.76827	-1.25383	Mica
i = 3	-0.06984	0.192897	Mare
i = 4	0.628587	1.157383	Mare
i = 5	1.327018	0.67514	Mare

2. Se identifică dreapta $Y = a_0 + a_1 x_1 + a_2 x_2$ (trebuie calculați coeficienții a) folosind metoda gradientului.

$$a_j = a_j - \text{learninRate} * \sum_{i=1}^n \left(\frac{1}{1 + e^{-(a_0 + a_1 x_1^i + a_2 x_2^i)}} - y^i \right) * x_j^i$$

```

from sklearn import linear_model
from random import random
import numpy as np
import math

def prediction(example, coef):
    s = 0.0
    for i in range(0, len(example)):
        s += coef[i] * example[i]
    return s

def sigmoidFunction(z):
    return 1.0 / (1.0 + math.exp(0.0 - z))

def cost_function(input, output, coef):
    noData = len(input)
    totalCost = 0.0
    for i in range(len(input)):
        example = input[i]
        predictedValue = sigmoidFunction(prediction(example, coef))
        realLabel = output[i]
        class1_cost = realLabel * math.log(predictedValue)
        class2_cost = (1 - realLabel) * math.log(1 - predictedValue)
        crtCost = - class1_cost - class2_cost
        totalCost += crtCost
    return totalCost / noData

def updateCoefs(input, output, coef, learningRate):
    noData = len(input)
    predictedValues = []
    realLabels = []
    for j in range(noData):
        crtExample = input[j]
        predictedValues.append(sigmoidFunction(prediction(crtExample, coef)))
        realLabels.append(output[j])
    for i in range(len(coef)):
        gradient = 0.0
        for j in range(noData):
            crtExample = input[j]
            gradient = gradient + crtExample[i] * (predictedValues[j] - realLabels[j])
        coef[i] = coef[i] - gradient * learningRate
    return coef

def train(input, output, learningRate, noIter):
    coef = [random() for i in range(len(input[0]))]
    costs = []
    for it in range(noIter):
        coef = updateCoefs(input, output, coef, learningRate)
        crtCost = cost_function(input, output, coef)
        costs.append(crtCost)

```

```

        return costs, coef

def test(input, coef):
    predictedLabels = []
    for i in range(len(input)):
        predictedValue = sigmoidFunction(prediction(input[i], coef))
        if (predictedValue >= 0.5):
            predictedLabels.append(1)
        else:
            predictedLabels.append(0)
    return predictedLabels

def accuracy(computedLabels, realLabels):
    noMatches = 0
    for i in range(len(computedLabels)):
        if (computedLabels[i] == realLabels[i]):
            noMatches += 1
    return noMatches / len(computedLabels)

def myLogisticRegression(input, output, learningRate, noIter):
    costs, coeficients = train(input, output, learningRate, noIter)
    computedLabels = test(input, coeficients)
    acc = accuracy(computedLabels, output)
    return acc

def SGDLogisticTool(x, y, learningRate, noEpoch):
    logreg = linear_model.LogisticRegression()
    logreg.max_iter = noEpoch
    logreg.fit(x, y)
    correct = sum(y == logreg.predict(x))
    return correct / len(x)

def testLogisticSGD():
    input = [[-1.117488473, -0.771588515], [-0.768273325, -1.253831338], [-0.06984303, 0.192897129], [0.628587266, 1.157382773], [1.327017562, 0.675139951]]
    output = [1, 0, 1, 0, 1]
    print("tool acc = ", SGDLogisticTool(input, output, 0.001, 4))
    print("my acc = ", myLogisticRegression(input, output, 0.001, 4))

testLogisticSGD()

```