

5. Clasificatorul Naive Bayes

Algoritmi de învățare generativi
Antrenarea clasificatorului Naive Bayes
Medierea Laplace
Predicția datelor

Abordarea prezentată în această lucrare de laborator construiește mai întâi un model ce descrie modul în care arată elefanții, urmat de construcția unui model separat ce descrie modul în care arată câinii. În final, pentru a clasifica un animal, putem calcula cât de mult se aseamănă el cu modelul ce descrie elefanții, pe de o parte, și cât de mult se aseamănă cu modelul ce descrie câinii, pe de altă parte.

5.1 Cerințe

Să se scrie un script Python ce va clasifica mesaje email scrise în limba engleză ca fiind spam sau non-spam.

5.1.1 Baza de date de antrenare

Pentru a implementa algoritmul, descărcați datele din arhiva "lab5Data.zip".

Baza de date este împărțită în două subseturi, și anume 700 de email-uri de antrenare și 260 de email-uri de testare. Fiecare subset conține 50% mesaje spam și 50% mesaje non-spam. Adicional, email-urile au fost procesate în felul următor:

- (a) Anumite cuvinte, precum "and", "the" și "of" sunt foarte comune în frazele din limba engleză și nu sunt relevante în decizia de a clasifica un mesaj ca spam sau nu. Aceste cuvinte au fost înlăturate din email-uri.
- (b) Cuvintele care au același înțeles, însă o terminație diferită, au fost ajustate în așa fel încât să aibă aceeași formă. Spre exemplu, "include", "includes" și "included" vor fi reprezentate de "include". Toate literele din corpul email-ului au fost convertite la litere mici.
- (c) Numerele și semnele de punctuație au fost înlăturate. Tab-urile, noile linii și spațiile au fost convertite la un singur spațiu.

Mai jos se găsesc două exemple de mesaje înainte și după procesare.

Mesajul non-spam "5-1361msg1" înainte de preprocesare

Subject: Re: 5.1344 Native speaker intuitions

The discussion on native speaker intuitions has been extremely interesting, but I worry that my brief intervention may have muddied the waters. I take it that there are a number of separable issues. The first is the extent to which a native speaker is likely to judge a lexical string as grammatical or ungrammatical per se. The second is concerned with the relationships between syntax and interpretation (although even here the distinction may not be entirely clear cut).

Mesajul non-spam "5-1361msg1" după preprocesare

re native speaker intuition discussion native speaker intuition
extremely interest worry brief intervention muddy waters number
separable issue first extent native speaker likely judge lexical
string grammatical ungrammatical per se second concern
relationship between syntax interpretation although even here
distinction entirely clear cut

Mesajul spam "spmsgc19" după preprocesare

financial freedom follow financial freedom work ethic
extraordinary desire earn least per month work home special
skills experience required train personal support need ensure
success legitimate homebased income opportunity put back control
finance life ve try opportunity past fail live promise

Arhiva "lab5Data.zip" conține fișierul "train-features-full.txt", ce reprezintă matricea de antrenare x , formată din 700 de linii și 2500 de coloane. Fiecare linie reprezintă un email, iar fiecare coloană reprezintă un cuvânt din dicționar. Un element dintr-o linie a matricei x reprezintă numărul de apariții în email al cuvântului reprezentat de acel element.

Fișierul "train-labels.txt" conține etichetele atribuite fiecărui email ($y = 1$ pentru email-

urile spam și $y = 0$ pentru email-urile non-spam) și are dimensiunea 700×1 .

5.1.2 Antrenarea

Pașii de antrenare ai algoritmului Naive Bayes, odată ce baza de date de antrenare a fost încărcată în Python, sunt următorii:

1. calculul ϕ_y ;
2. calculul fiecărui $\phi_{j|y=1}$ pentru fiecare cuvânt din dicționar și stocarea rezultatelor într-un vector;
3. calculul fiecărui $\phi_{j|y=0}$ pentru fiecare cuvânt din dicționar și stocarea rezultatelor într-un vector.

5.1.3 Testarea

Odată ce parametrii modelului au fost calculați, ei pot fi utilizați în efectuarea predicțiilor. Pentru aceasta se vor folosi fișierele "test-features-full.txt" și "test-labels.txt", ambele având structura fișierelor "train-features-full.txt", respectiv "train-labels.txt".

Pașii utilizați pentru clasificarea documentelor sunt următorii:

1. pentru fiecare document din baza de date de testare se calculează $\log p(x|y = 1) + \log p(y = 1)$;
2. similar, se calculează $\log p(x|y = 0) + \log p(y = 0)$;
3. se compară cele două cantități de la punctele (1) și (2) și se ia decizia de clasificare a email-ului în spam sau non-spam, luând în considerare cea mai mare valoare.