



مدرسه پردازش و تحلیل داده

مدرسه پردازش و تحلیل داده دقیقه

K-نزدیک ترین همسایه

K Nearest Neighbors

سعید مجیدی

یادگیری ماشین با پایتون

بهار ۱۴۰۴

FRIENDS

You Are Genetically Similar to Your Friend

Friends are as genetically related as fourth cousins.

Posted November 3, 2020 | Reviewed by Ekua Hagan



Social Proximity Effect: Your Friends' Habits Will Become Your Habits

by tyler tervooren | 4 minute read

The gist: You'll mirror the habits of the people you spend the most time with. The more time you spend with people who already practice them.

KNN BE LIKE



@beingamit99

"SHOW ME YOUR FRIENDS AND I WILL TELL WHO YOU ARE."

الگوریتم K-نزدیک‌ترین همسایه

K-Nearest Neighbors Algorithm (KNN)

- معروف‌ترین الگوریتم نمونه‌محور، یک الگوریتم بانظارت

- یادگیری: ندارد

- پارامتر: K

- پیش‌بینی برای یک نمونه‌ی جدید:

- K-نزدیک‌ترین همسایه‌ی نمونه‌ی جدید را در بین نمونه‌های آموزشی پیدا کن

- مسئله دسته‌بندی: برچسبی که در بین همسایه‌ها اکثریت را دارد به نمونه جدید نسبت بده


- مسئله رگرسیون: میانگین برچسب‌های همسایه‌ها را به نمونه جدید نسبت بده.

$$d(\mathbf{p}, \mathbf{q}) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2}$$

- نزدیک‌ترین معمولا براساس فاصله اقلیدسی محاسبه می‌شود



مثال



K= 1 ●

K= 5 ▲


K= 7 ●

تعمیم (GENERALIZATION)

- هدف اصلی هر الگوریتم بانظارت، پیش‌بینی صحیح برای نمونه‌هایی است که تاکنون دیده نشده‌اند.
- انتخاب پارامترهایی که خطای مدل را تنها بر روی داده آموزشی کم می‌کنند، عاقلانه نیست
- کاهش خطا = افزایش دقت ($\text{Error} = 1 - \text{accuracy}$)
- هدف آن است که ماشین قواعد صحیح حاکم بر داده را یاد بگیرد و به وجود نویز در داده‌ها توجه نکند.


K = 1

Training data



error = 0.0


Testing data



error = 0.15


K = 3

Training data



error = 0.0760


Testing data



error = 0.1340


K = 7

Training data



error = 0.1320


Testing data



error = 0.1110


K = 21

Training data



error = 0.1120


Testing data



error = 0.0920


انتخاب بهترین پارامتر

- با افزایش K خطای آموزش ممکن است افزایش یابد.
- انتخاب بهترین پارامتر از طریق Cross Validation
 - به ازای هر مقدار پارامتر K
 - هر بار داده آموزشی را به دو دسته مجموعه آموزشی و مجموعه اعتبارسنجی تقسیم می‌کنیم.
 - خطای آموزش را هر بار بر روی مجموعه اعتبارسنجی محاسبه می‌کنیم.
 - مقدار پارامتر K که کمترین خطا روی مجموعه اعتبارسنجی داشت را انتخاب می‌کنیم.



نرمال سازی / استاندارد سازی ویژگی های

- **مشکل:** فاصله ی اقلیدسی به مقیاس و محدوده ی مقادیر ویژگی ها حساس است.
- ویژگی هایی که مقیاس و محدوده ی بزرگ تری دارند، اثر ویژگی های با محدوده کمتر را کم رنگ می کنند.



$$\text{euclidean}(A, B) = \sqrt{(125.000 - 100.000)^2 + (52 - 45)^2}$$

25000^2 Contribution of bank deposit

7^2 Contribution of age

- مثال: داده بانکی مشتریان

- موجودی حساب (از ۰ تا ۱۰۰۰ میلیارد)
- سن (از ۱ تا ۲۰۰)

نرمال سازی / استاندارد سازی

- راه حل: تغییر محدوده‌ی مقادیر ویژگی‌ها به گونه‌ای که همه محدوده‌ی یکسانی داشته باشند.

- نرمال سازی داده (Normalization)

- تغییر دامنه مقادیر به بازه ۰ تا ۱ با استفاده از مقادیر ماکزیمم و مینیمم هر ویژگی

$$X_{normalised} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

- استاندارد سازی داده (Standardization)

- تغییر دامنه مقادیر هر ویژگی به نحوی که مقادیر توزیع نرمال با میانگین ۰ و واریانس ۱ داشته باشند.

$$X_{standarised} = \frac{X - \mu}{\sigma}$$

پیاده‌سازی

```
def knn(trainingSet, testInstance, k):  
    distances = {}  
    sort = {}  
  
    length = testInstance.shape[1]  
  
    for x in range(len(trainingSet)):  
        dist = EuclideanDistance(testInstance, trainingSet.iloc[x], length)  
        distances[x] = dist[0]  
    sortdist = sorted(distances.items(), key=operator.itemgetter(1))  
    neighbors = []  
    for x in range(k):  
        neighbors.append(sortdist[x][0])  
    Votes = {} #to get most frequent class of rows  
    for x in range(len(neighbors)):  
        response = trainingSet.iloc[neighbors[x]][-1]  
        if response in Votes:  
            Votes[response] += 1  
        else:  
            Votes[response] = 1  
    sortvotes = sorted(Votes.items(), key=operator.itemgetter(1), reverse=True)  
    return(sortvotes[0][0], neighbors)
```

