

Припрема података

Ненад Митић

Математички факултет
nenad@matf.bg.ac.rs

Увод

- Различити извори и формати података
- Недостајући и неконзистентни подаци
- Неопходна је припрема (препроцесирање)
 - Издавање карактеристика
 - Преносивост типова података
 - Чишћење података
 - Избор и трансформација
 - Редукција података

Издвајање карактеристика

- Издвајање карактеристика из равних/неструктуираних података
- Карактеристика која се издваја зависи од апликације (слике, веб логови, текстуални подаци, ...)
- Подаци могу да садрже хетерогене типове

Преносивост типова података

- Неке карактеристике онемогућују примену готових алата
- Поједини алгоритми раде само са одређеним типовима података (промена типа?)
- Могуће губљење информација
- Најчешћа трансформација (категоричких) у нумеричке податке

Преносивост типова података

Преносивост података између типова

- Дискретизација - непрекидни у категоричке атрибуте
 - Бинаризација - категорички у нумеричке атрибуте
 - Текстуални у нумеричке атрибуте
 - Дискретне ниске у нумеричке податке
 - ...

Дискретизација

Трансформација непрекидних у категоричке атрибуте

- Обично се примењује на атрибуте у класификацији или правилима придрживања
- Кораци у трансформацији
 - одабрати број категорија n
 - интервал бројева се дели на n подинтервала
 - све вредности из једног подинтервала се пресликају у исту категоричку вредност
- Између добијених вредности (ознака) не постоји уређење (категоричке вредности!)

Начин избора интервала

- Једнаке ширине интервала
 - Ако су a и b границе интервала $[a, b]$ тада је $b - a$ једнако за све интервале
 - За сваки атрибут се интервал $[min, max]$ дели на n подинтервала
 - Некоректно ако је дистрибуција елемената неравномерна по интервалима

Начин избора интервала (наставак)

- Једнаки \log -интервали


- Ако су a и b границе интервала $[a, b]$ тада је $\log(b) - \log(a)$ једнако за све интервале
 - Ефекат у случају геометријског повећања граница интервала $[a, a \times \alpha], [a \times \alpha, a \times \alpha^2]$, итд. за $\alpha > 1$.
 - Некоректно ако је дистрибуција елемената неравномерна по интервалима

- Ако дистрибуција елемената може да се моделира функционалом f тада се бирају интервали $[a, b]$ такви да је $f(b) - f(a)$ једнако за све интервале


Начин избора интервала (наставак)

- Једнак број елемената у интервалу
 - Вредности атрибута се преброје, и добијени број k се подели са n
 - Вредности атрибута се сортирају и у сваки интервал се смешта k/n елемената
 - Пример - *Binning* чвор у СПСС Моделеру

Пример - број класа познат




По 3 категорије за x и y




По 5 категорија за x и y


Пример - број класа непознат




Оригинални подаци



Интервали једнаке ширине



Једнака учесталост



К-средине

Бинаризација

Бинаризација - трансформација непрекидних и дискретних атрибута у бинарне

- Обично се примењује на атрибуте у анализи заснованој на правилима придрживања
- Чест редослед: непрекидни → категорички → скуп бинарних атрибута
- Поступак
 - Ако категорички атрибут има p вредности формира се p бинарних атрибута
 - Сваки бинарни атрибут одговара једној вредности категоричке променљиве
 - У једном реду тачно један од p атрибута има вредност 1

Текстуални у нумеричке податке

- Представљање текстуалних података преко ретких нумеричких вектора није погодно за највећи број ИП метода
- Ограничен број мера (нпр. косинусна мера, али не и Еуклидско растојање)
- Латентна семантичка анализа (LSA) - текст се преводи у не-ретку репрезентацију мање димензије
- После трансформације документ $\bar{X} = (x_1, x_2, \dots, x_d)$ се скалира функцијом $\frac{1}{\sqrt{\sum_{i=1}^d x_i^2}}(x_1, x_2, \dots, x_d)$
- На овако добијене податке може да се примени Еуклидско растојање
- У пракси - ИП алгоритми се примењују директно на податке добијене са LSA док се даља трансформација не ради

Дискретне ниске у нумеричке податке

Трансформација се врши у два корака

- 1 Дискретне ниске се конвертују у скуп бинарних временских серија чији је број једнак броју различитих симбола
- 2 Свака серија се конвертује у мултидимензиони вектор помоћу трансформације таласићима. Особине из ових вектора се комбинују и формира се мултидимензионални слог

Пример: ДНК секвенца

```
ACACACTGTGACTG
10101000001000
01010100000100
00000010100010
00000001010001
```

Чишћење података

Аспекти

- 1 Рад са недостајућим подацима
- 2 Рад са некоректним подацима
- 3 Рад са дуплираним подацима
- 4 Скалирање и нормализација

Рад са недостајућим подацима

Разлози за појаву

- Информације нису прикупљене (нпр. људи одбијају да прикажу своју тежину, старост, величину плате, ...)
- Атрибути нису применљиви у свим случајевима (нпр. плата није применљива на децу)
- Шта радити у таквим случајевима?

Руковање недостајућим вредностима

- 1 Комплетни слогови (цео објекат) који садрже такав податак се бришу
- 2 Недостајућа вредност се процењује и уноси (импутација)
- 3 Неки алгоритми могу да обрађују слогове/атрибуте са недостајућим подацима
- 4 Замена могућим вредностима (зависи од алгоритма)

Рад са некоректним подацима

Аспекти

- 1 Откривање некозистентности (нпр. подаци из више извора који се односе на исту ствар су различити)
- 2 Доменско знање
- 3 Метода оријентисана ка подацима

Рад са дуплираним подацима

Најчешће се јављају код спајања података из хетерогених извора

- Пример: иста особа са више електронских адреса
- Најчешће се елиминишу из материјала
- Када дуплиране податке не треба брисати?

Скалирање и нормализација

- Трансформација променљиве означава трансформацију која се примењује на све вредности те променљиве
- За сваки објекат, трансформација се примењује на вредност променљиве за тај објекат
- Једноставне функције, нпр. \sqrt{x} , x^k , $\log(x)$, e^x , $|x|$, $1/x$
- У статистици се често користе \sqrt{x} , $\log(x)$ и $1/x$ ради трансформације података који немају нормалну расподелу у податке који имају нормалну расподелу
- У ИП постоје и други разлози - нпр. ако је вредност променљиве између 1 и 1.000.000.000 применом \log функције се добијају бољи односи код поређења
- Опрез - могућа промена природе података (нпр. трансформацијом са $1/x$)

Скалирање и нормализација

- Потреба за нормализацијом - више атрибута који су различито скалирани
- Стандардизација: нека j -ти атрибут има средњу вредност μ_j и стандардну девијацију σ_j . Тада се вредност x_i^j j -тог атрибута слога \bar{X}_i нормализује применом израза $z_i^j = \frac{x_i^j - \mu_j}{\sigma_j}$
- За нормалну расподелу добијене вредности најчешће се налазе у интервалу $[-3, 3]$
- За свођење у интервал $[0, 1]$ се примељује *min-max* скалирање $y_i^j = \frac{x_i^j - min_j}{max_j - min_j}$
- Пример - *Transform*, *Derive*, *Filler* чворови у СПСС Моделеру

Редукција и трансформација података

Мања количина података - ефикаснија примена алгоритма

- 1 Агрегација
- 2 Узимање узорака
- 3 Избор карактеристика
- 4 Редукција помоћу ротације оса
- 5 Остале методе димензионе редукције

Агрегација

Комбиновање два или више атрибута (или објекта) у један
Сврха

- 1 Редукција података (смањивање броја атрибута/објеката)
- 2 Промена скале (нпр. уместо 365 дана добија се 12 месеци)
- 3 'Стабилнији' подаци (агрегирани подаци имају тенденцију ка мањим одступањима)
- 4 ...

Узимање узорака

- Избор узорака је главна техника која се користи у истраживању података
- Често се користи како за прелиминарна истраживања тако и за коначне резултате анализе података
- Статистичари бирају узорке јер је добијање комплетног скупа података који су од интереса јако скupo и временски захтевно
- Избор узорака се користи у ИП јер је обрада комплетног скупа података који је од интереса такође јако скупа или временски захтевна

Узимање узорака

Кључни принципи за ефективан избор узорака су


- Коришћењем узорака који су репрезентативни добија се ефекат скоро исти као да је рађено на комплетном скупу података
- Узорак је репрезентативан ако има апроксимативно исте особине као и оригинални скуп података

Типови узорака

- Једноставан случајни узорак (једнака вероватноћа за избор било које случајне ставке)
- Са и без враћања (дупликата из оригиналног скупа)
- Пристрасно узорковање (неки подаци су важнији од других)
- Стратификовано узорковање (узорковање са раслојавањем)
 - Подаци се деле у више делова, а затим се бира случајни узорак из сваког од тих делова

Величина узорка

Величина узорка треба да буде довольно велика да се не наруши структура објекта или уклоне интересанте особине







Величине узорка су редом 8000, 2000 и 500 тачака

Избор карактеристика

- 1 Један од начина за смањење димензионалности
- 2 Елиминација редундантних карактеристика
- 3 Елиминација ирелевантних карактеристика
- 4 Развијен је велики број техника, поготову за класификацију
- 5 Често се формирају нови атрибути који укључују важне карактеристике због ефикасније обраде
- 6 Пресликавање у нови простор (нпр. Фуријеова анализа, таласићи)

Редукција помоћу ротације оса

Основна идеја



Редукција помоћу ротације оса

- Аутоматско уклањање координатних оса помоћу ротације?
- *PCA* (Principal Component Analysis)
- *SVD* (Singular Value Decomposition)

Principal Component Analysis

- Смањење броја димензија података
- Налажење образца у подацима велике димензионалности
- Визуелизација података велике димензионалности

Principal Component Analysis (наставак)

- Основна идеја: ротација података у систем са осама где је највећи број варијанси покривен најмањим бројем димензија
- Нови систем са осама зависи од корелације између атрибута
- *PCA* се (најчешће) примењује после одузимања средње вредности од сваке тачке

Ostale metode dimenzione redukcije

- SVD (eng. *Singular Value Decomposition*)
- LSA (eng. *latent semantic analysis*)
- Talasići
- Furijeove transformacije
- Analiza faktora
- Multidimenziono skaliranje (MDS), Brzo preslikavanje, ISOMAP
- Spektralna transformacija grafova
- ...