4. Sailkapen-zuhaitzak

Espezialitatea: Konputazioa, hirugarren ikasmaila
Titulazioa: Informatika Ingeniaritzako Gradua
Konputazio Zientzia eta Adimen Artifiziala saila
Universidad del País Vasco - Euskal Herriko Unibertsitatea

Sarrera

- Sailkapen-zuhaitz bat egitura hierarkikoan antolatutako baldintza-multzo bat da. Zuhaitzaren errotik hasi eta hostoetako batera iritsi arte betetzen diren baldintzei jarraituz hartuko da azken erabakia.
- Sailkapen-zuhaitz bat induzitzea, modu errekurtsiboan aldagai iragarleen definizio-eremua partizio disjuntuetan zatitzean datza.
- Partizio bat erregelen multzo bat da non elkarrekiko disjuntuak diren eta guztien artean definizio-eremu osoa hartzen duten.

Sarrera

- Indukzioaren ataza honakoan datza: entrenamendurako kasuen multzoan oinarrituz (training set) sailkapenerako erregela bat garatu behar da edozein kasuren atributuak aztertuz bere klasea iragarriko duena
- Atributuek nahiko informazio ematen al dute indukzioaren ataza burutu ahal izateko?
- Atributu egokiak erabiliz, test-multzoko kasuak ondo sailkatuko dituen erabaki-zuhaitz bat eraikitzea da helburua
- Normalean, erabaki-zuhaitz asko aurki daitezke

Oinarrizko algoritmoa

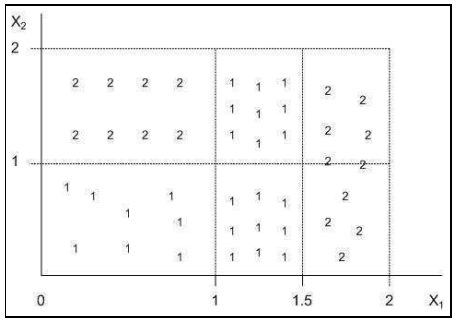

X_1 eta X_2 aldagai iragarleen bidez eta bi balio posible dituen C klase-aldagaiaren bidez karakterizatutako kasuen adierazpena planoan

Oinarrizko algoritmoa

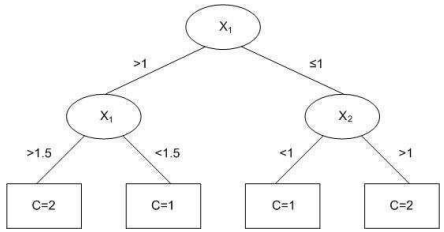

Aurreko adibideari dagokion sailkapen-zuhaitza

Sailkapen-zuhaitzarekin baliokide den erregela-multzoa:

R_1 : If $X_1 > 1.5$ then $C = 2$
R_2 : If $1 < X_1 < 1.5$ then $C = 1$
R_3 : If $X_1 < 1$ and $X_2 < 1$ then $C = 1$
R_4 : If $X_1 < 1$ and $X_2 > 1$ then $C = 2$

Oinarrizko algoritmoaren sasikodea: TDIDT (Top Down Induction of Decision Trees)

Input: Etiketatutako N kasuen D multzoa, horietako bakoitza n aldagai iragarleren bidez $X_1, \ldots, X_n$, eta C klase-aldagaiaren bidez karakterizatuta dagoena
Output: Sailkapen-zuhaitza
Begin TDIDT (Top Down Induction of Decision Trees)
  if D multzoko kasu guztiak c klase berekoak badira
    then
      induzkioaren emaitza erpin simple bat da (hostoa), c etiketaduna
    else
      begin
        1. Informazio handieneko X_r aldagaia aukeratu, $x_r^1, \ldots, x_r^{n_r}$ balioak dituena
        2. X_r aldagaiaren n_r balioen arabera D-ren partizioa egin: $D_1, \ldots, D_{n_r}$ sortu
        3. $D_1, \ldots, D_{n_r}$ horietarako n_r azpizuhaitz $T_1, \ldots, T_{n_r}$ eraiki
        4. X_r eta n_r azpizuhaitzak $T_1, \ldots, T_{n_r}$ lotu $x_r^1, \ldots, x_r^{n_r}$ balioen bidez
      end
  endif
End TDIDT

Erabaki-zuhaitzak

Erabaki-zuhaitzen indukziorako algoritmoak honakoetan bereiztzen dira nagusiki:

- Partizioen aukeraketarako irizpideak
- Inausketarako estrategiak

ID3 algoritmoa

- Informazio handieneko aldagaiaren aukeraketa aldagai iragarleen eta klase-aldagaiaren arteko elkarrekiko-informazio kantitatean oinarritzen da (informazio-irabazia edo information gain):

$$I(X_i, C) = H(C) - H(C|X_i)$$

- Matematikoki froga daiteke irizpide horrek balio-kopuru handieneko aldagaien aukeraketari lehentasuna ematen diela
- Aldez aurretiko aldagai-aukeraketa egiten da, X_i aldagai iragarle bakoitzaren eta C klase-aldagaiaren arteko independentzia-test batean oinarritua (prepruning)

C4.5 algoritmoa

- C4.5 algoritmoan (Quinlan, 1993), honela definitzen den irabazi-ratio edo gain ratio irizpidean oinarritzen da informazio handieneko aldagaiaren aukeraketa

$$\frac{I(X_i, C)}{H(X_i)}$$

- Matematikoki froga daiteke balio posible gehieneko aldagaiei ez zaiela lehentasunik ematen aldagaien aukeraketan
- Sailkapen-zuhaitza induzitu eta gero zuhaitzaren inausketa egiten da, hipotesi-test batean oinarrituta; adar bat hedatu izanak merezi ote duen erabaki behar da (postpruning)

C4.5 algoritmoa

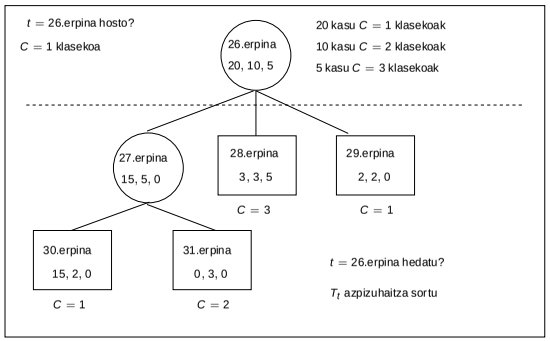

Irudia: $C4.5$ algoritmoaren inausketa prozesurako adibidea

C4.5 algoritmoa

Zuhaitzaren inausketa prozesua

- $N(t) = 35$, $t = 26$ erpineko kasu-kopurua
- $e(t) = 10 + 5 = 15$, t erpinean gaizki sailkatuta dagoen kasu-kopurua
- $n'(t) = e(t) + \frac{1}{2} = 15,5$, $e(t)$ren jarraitasunezko zuzenketa
- T_t, t erpinetik abiatuz hedatuko den azpizuhaitza
- $h(T_t) = 4$, T_t azpizuhaitzaren hosto-kopurua
- $n'(T_t) = \sum_{i=1}^{h(T_t)} e(i) + \frac{h(T_t)}{2} = 2 + 0 + 6 + 2 + \frac{4}{2} = 12$
  T_t azpizuhaitzaren hostoetan dagoen errore-kopurua
- $S(n'(T_t)) = \sqrt{\frac{n'(T_t)[N(t) - n'(T_t)]}{N(t)}} = \sqrt{\frac{12(35-12)}{35}} \simeq 2.8$
  $n'(T_t)$ren desbideratzea

t erpina hedatu egingo da $\Leftrightarrow$ $n'(T_t) + S(n'(T_t)) < n'(t)$ $\Leftrightarrow$ $12 + 2.8 < 15.5$
26 erpina hedatu egingo da, 28, 29, 30 eta 31 erpinak sortuz

Bibliografia

- Quinlan J.R. (1986) *Induction of decision trees*. Machine Learning, 1(1), 81-106
- Quinlan J.R. (1993) *C4.5: Programs for Machine Learning*. Morgan Kaufmann
- http://en.wikipedia.org/wiki/Decision_tree_learning
- http://en.wikipedia.org/wiki/ID3_algorithm
- http://en.wikipedia.org/wiki/C4.5_algorithm
- http://en.wikipedia.org/wiki/Decision-tree_pruning
- http://en.wikipedia.org/wiki/Overfitting
- Overfitting, 9min slidecast: http://blog.lokad.com/journal/2009/4/22/overfitting-when-accuracy-measure-goes-wrong.html