

Pairwise Naive Bayes Classifier

Jan-Nikolas Sulzmann¹

¹nik.sulzmann@gmx.de
Fachbereich Knowledge Engineering
Technische Universität Darmstadt

Gliederung

- 1 Ziel dieser Arbeit
- 2 Naive Bayes Klassifizierer
- 3 Klassenbinarisierung
- 4 Pairwise Naive Bayes
 - Klassenbinarisierung
 - Alternative paarweise Methoden
 - Erweiterung von Round Robin durch Bagging & Boosting
- 5 Ausblick

Kurzfassung

Ziel

Verbesserung der Performanz des Naive Bayes Klassifizierers durch Methoden der paarweisen Klassenbinarisierung

Verwendete Methoden

- Round Robin Klassenbinarisierung
- Alternative Methoden
- Ensemble-Methoden: Bagging und Boosting

Kurzbeschreibung

Naive Bayes Klassifizierer

- Bayes'sche Lernverfahren
 - d.h. auf dem Satz von Bayes basierend
 - Fundierte wahrscheinlichkeitstheoretische Grundlage
 - Vorhersage der wahrscheinlichsten Klasse
- Effizient
 - Zum Teil bessere Performanz als aktuelle Lernverfahren, z.B. Neuronale Netze, Nearest Neighbour oder Entscheidungsbäume
- Einfach implementierbar
- Flexibel
 - Anwendbar auf strukturierte (z.B. Tabellen) und unstrukturierte Daten (z.B. Texte, Web-Dokumente)

Satz von Bayes

Satz von Bayes

Für zwei Zufallsereignisse A und B gilt

$$\Pr(A|B) = \frac{\Pr(B|A) \Pr(A)}{\Pr(B)}$$

Bedingte Wahrscheinlichkeit

- Für zwei Zufallsereignisse A und B gilt

$$\Pr(A|B) = \frac{\Pr(A \wedge B)}{\Pr(B)}$$

- Die Wahrscheinlichkeit, daß ein Zufallsereignis A auftritt, wenn wir bereits das Zufallsereignis B beobachtet haben

Naive Bayes Klassifizierer

Ziel

Bestimmung der wahrscheinlichsten Klasse c unter Beobachtung des Beispiels D anhand der Trainingsdaten

Gegeben

- Menge von Klassen
- Trainingsbeispiele
- Beispiele durch Attributwerte beschrieben
- a_i Wert des Attributes A_i
- Beispiel $D = (a_1, a_2, \dots, a_n)$

Vorläufige Version

$$\begin{aligned} & \arg \max_c \Pr(c|D) \\ &= \arg \max_c \frac{\Pr(D|c) \Pr(c)}{\Pr(D)} \\ &= \arg \max_c \Pr(D|c) \Pr(c) \end{aligned}$$

Unabhängigkeitsannahme

Ziel

Bestimmung von $\Pr(D|c) = \Pr(a_1, a_2, \dots, a_n|c)$ anhand der Trainingsbeispiele

Problem

Relative Häufigkeit der Beispiele $D = (a_1, a_2, \dots, a_n, c)$ bezüglich Klasse c ist eine schlechte Abschätzung, da diese Beispiele selten oder gar nicht vorkommen

Lösung

- **naive** Annahme über Unabhängigkeit der Attribute
- $\Pr(a_1, a_2, \dots, a_n|c) = \prod_{i=1}^n \Pr(a_i|c)$

Abschätzung der Wahrscheinlichkeiten

Ziel

Abschätzung der Wahrscheinlichkeiten $\Pr(a|c)$ und $\Pr(c)$

Abschätzung von $\Pr(a|c)$

- $\Pr(a|c) = \frac{n_{a \wedge c}}{n_c}$
- $n_{a \wedge c}$: absolute Häufigkeit von Beispielen mit Attributwert a und Klasse c
- n_c : absolute Häufigkeit von Klasse c
- Problem:

$$n_{a \wedge c} = 0 \Rightarrow \Pr(c|D) = 0$$

Lösung für $\Pr(a|c)$

- Laplace-Abschätzung:
 $\Pr(a|c) = \frac{n_{a \wedge c} + 1}{n_c + v}$
- v : Anzahl unterschiedlicher Attributwerte

Abschätzung von $\Pr(c)$

- $\Pr(c) = \frac{n_c}{n}$
- n : Anzahl von Trainingsbeispielen

Illustratives Beispiel

$D = (Warm, Regen), Golf?$

$$\Pr(+)=2/5, \Pr(-)=3/5$$

$$\Pr(W|+)\Pr(R|+)=\frac{3}{5} * \frac{1}{5} = \frac{3}{25}$$

$$\Pr(W|-)\Pr(R|-)=\frac{1}{6} * \frac{2}{6} = \frac{1}{18}$$

$$\frac{3}{25} * \frac{2}{5} = \frac{6}{150}, \frac{1}{18} * \frac{3}{5} = \frac{5}{150}$$

$$\Pr(+|W, R) = 6/11$$

$$\Pr(-|W, R) = 5/11$$

Abk.: W = Warm, R = Regen

Temp.	Aussicht	Golf?
Warm	Sonnig	ja
Warm	Bewölkt	ja
Mild	Bewölkt	nein
Kalt	Regen	nein
Kalt	Bewölkt	nein
	ja	nein
Kalt	0	2
Mild	0	1
Warm	2	0
Bewölkt	1	2
Regen	0	1
Sonnig	1	0

Grundidee

Problem

- Reale Klassifikationsprobleme sind häufig Multiklassenprobleme
- Aber viele Klassifizierer sind inhärent binär
- d.h sie können nur mit binären Probleme umgehen
- Bekannte Vertreter sind z.B. Perceptrons und SVM

Lösung

- Zerlegung des Multiklassenproblem in mehrere binäre Probleme
- Decodierung der Vorhersagen der binären Klassifizierer
- Kann auch bei nichtbinären Klassifizierer zu einer Verbesserung führen

Typen der Klassenbinarisierung

Behandlung eines Multiklassenproblem

- Ungeordnete Klassenbinarisierung
 - Transformation in m binäre Probleme
 - Jeweils eine Klasse gegen die anderen
 - Benötigt Decodierung der Vorhersagen
- Geordnete Klassenbinarisierung
 - Wie ung. KB mit sukzessivem Ausschluß
 - Benötigt keine Decodierung
- Round Robin Klassenbinarisierung
 - Transformation in $m(m-1)/2$ binäre Probleme
 - Je Klassenpaar ein Klassifikator
 - Benötigt Decodierung der Vorhersagen



Voting & Weighted Voting

Voting

- Jeder Klassifizierer stimmt für eine der Klassen
- Vorhersage der Klasse mit den meisten Stimmen
- z.B. Bagging

Weighted Voting

- Berechne gewichtete Summe der Stimmen für jeden Klassifizierer
- Gewichte normalerweise abhängig von
 - dem Vertrauen des Klassifizierers auf seine Vorhersage (z.B. geschätzte Wahrscheinlichkeit einer Klasse)
 - der Fehlerabschätzung des Klassifizierers (z.B. Boosting)

Round Robin Klassenbinarisierung mit Naive Bayes

Voting

$$\arg \max_{c_i} \sum_{j \neq i} [\Pr(c_i | D, c_{ij})]$$

Weighted Voting

$$\arg \max_{c_i} \sum_{j \neq i} \Pr(c_i | D, c_{ij})$$

Ergebnisse

- RR mit Voting ist äquivalent zu RR mit Weighted Voting, da

$$[\Pr(c_i | D, c_{ij})] \leq [\Pr(c_j | D, c_{ij})] \Leftrightarrow \Pr(c_i | D, c_{ij}) \leq \Pr(c_j | D, c_{ij})$$
- RR mit Weighted Voting ist äquivalent zu regulärem NB, da

$$\frac{\Pr(c_i | D, c_{ij})}{\Pr(c_j | D, c_{ij})} = \frac{\Pr(c_i | D)}{\Pr(c_j | D)}$$

Wahrscheinlichkeitstheoretischer Ansatz

Ansatz

$$\Pr(c_i|D) = \frac{1}{(m-1)} \sum_{j \neq i} \Pr(c_i|D, c_{ij}) \Pr(c_{ij}|D)$$

- $v_{ij} = \Pr(c_i|D, c_{ij}) = \frac{\Pr(c_i|D)}{\Pr(c_i|D) + \Pr(c_j|D)}$
- Für $w_{ij} = w_{ji} = \Pr(c_{ij}|D)$ gibt es zwei Möglichkeiten

Reguläre Berechnung von w_{ij}

- Reguläres „Abzählen“
- Häufigkeitstabelle
 - 1 Zelle je Kombination v. Attributwert und Klasse

Paarweise Berechnung von w_{ij}

- „Abzählen“ für Klassenpaare
- Häufigkeitstabelle
 - 1 Zelle je Kombination v. Attributwert und Klassenpaar

Resultierende Methoden

Anwendungsmöglichkeiten

- v_{ij} verwendbar zur (un-)gewichteten Abstimmung
- $w_{ij} = w_{ji}$ verwendbar als Gewicht

PNB1

$$\arg \max_i \sum_{\substack{j \neq i \\ v_{ij} \geq v_{ji}}} w_{ij}$$

PNB2

$$\arg \max_i \sum_{j \neq i} v_{ij} * w_{ij}$$

PNB3

$$\arg \max_i \sum_{\substack{j \neq i \\ \Pr(c_i) \geq \Pr(c_j)}} w_{ij}$$

PNB4

$$\arg \max_i \sum_{j \neq i} \frac{\Pr(c_i)}{\Pr(c_i) + \Pr(c_j)} w_{ij}$$

Vergleich mit Naive Bayes: Ergebnisse

Accuracy (Win/Draw/Loss)

Methode	Regulär	Paarweise
PNB1	83,34 (0/36/0)	83,27 (4/24/8)
PNB2	83,34 (0/36/0)	83,29 (7/19/10)
PNB3	71,47 (3/3/30)	70,17 (3/0/33)
PNB4	73,49 (4/4/28)	72,45 (4/0/32)

- Reguläre PNB1 und PNB2 äquivalent zu NB
- Paarweise PNB1 und PNB2 schlechter als NB
- PNB3 und PNB4 signifikant schlechter (99%)

Decodierungsmethoden

Idee

- Schätze über Kenntnis der $\Pr(c_j|D, c_{ij})$ alle $\Pr(c_j|D)$ ab
 - : Idee: $\frac{\Pr(c_j|D, c_{ij})}{\Pr(c_j|D, c_{ij})} \stackrel{!}{\approx} \frac{\Pr(c_j|D)}{\Pr(c_j|D)}$
- Problem: für NB gilt $\frac{\Pr(c_j|D, c_{ij})}{\Pr(c_j|D, c_{ij})} \stackrel{!}{=} \frac{\Pr(c_j|D)}{\Pr(c_j|D)}$
- \Rightarrow Als Decodierungsmethode für reguläres RR mit NB nicht geeignet, da Resultat äquivalent zu NB

Methoden

- M. von Price, Kner, Personnaz und Dreyfus
 - $\Pr(c_j|D) = (\sum_{j \neq i} \frac{1}{\Pr(c_i|D, c_{ij})} - (\#Klassen - 2))^{-1}$
- M. von Refregier und Vallet: Lösung eines LGS
- M. von Hastie und Tibshirani: Konvergenter Algorithmus

Ensemble-Methoden

Idee

- Lerne anstatt einzelnen Klassifizierer eine Menge von Klassifizierern
- Bilde ein Ensemble unterschiedlicher Klassifizierer anhand derselben Trainingsmenge
- Kombiniere die Vorhersagen dieser Klassifizierer (Decodierung)

Motivation

- Reduziert Varianz: Ergebnisse sind weniger abhängig von den Eigenheiten einer einzelnen Trainingsmenge
- Reduziert Bias: eine Kombination von mehreren Klassifizierer kann ein aussagekräftigeres Konzept darstellen ein einzelner Klassifizierer

Bagging & Boosting

Idee

- Veränderung der Trainingsmenge, um unterschiedliche Klassifizierer zu erhalten
- Kombination der Vorhersagen durch (Weighted) Voting zur endgültigen Vorhersage
- Unser Ansatz: Anwendung auf Klassenpaare C_{ij}

Bagging

- Parallele Berechnung
- Resampling
- Rauschen kein Problem
- Voting

Boosting

- Sequentielle Berechnung
- Reweighting
- Rauschen problematisch
- Weighted Voting

Vergleich von NB, Bagging und Boosting

(W/D/L)	Bagging	AdaboostM1	Naive Bayes
Bagging	-	(11/0/25)	(16/0/20)
AdaboostM1	(25/0/11)	-	(24/0/12)
Naive Bayes	(20/0/16)	(12/0/24)	-

- Verwenden für Boosting für AdaboostM1
- Bagging schlechter als Naive Bayes
- AdaboostM1 signifikant besser als Naive Bayes und Bagging (95%)

AdaBoostM1 & Bagging: Regulär & Alternativ

Vergleich: alternativ decodierte Ensembles mit regulären Ensembles

(W/D/L)	HT	PKPD	RV	Voting
AdaboostM1	(12/16/5)	(13/16/6)	(1/16/14)	(13/16/6)
Bagging	(7/14/11)	(7/19/9)	(6/16/10)	(7/19/9)

- Vergleich der Decodierungsmethoden
 - AdaboostM1: HT, PKPD und Voting signifikant besser, RV signifikant schlechter
 - Bagging: alle schlechter
- Vergleich mit Naive Bayes
 - AdaboostM1: HT, PKPD und Voting signifikant besser
 - Restliche Methoden (signifikant) schlechter

Noch zu tun

- Bagging & Boosting der alternativen Methoden
- Vergleich mit dem Bagging/Boosting der Round Robin Klassenbinarisierung
- Beide Fälle noch mit Weighted Voting testen