

베이지안 네트워크를 이용한 전자상거래 고객들의 성향 분석

Analysis of Web Customers Using Bayesian Belief Networks

양 진산, 장 병탁

서울대학교 컴퓨터공학부

Jinsan Yang and Byoung-Tak Zhang

School of Computer Science and Engineering, Seoul National University

{jsyang, btzhang}@scai.snu.ac.kr

Abstract

전자 상거래에서 고객의 성향을 이해하기 위해서는 일반적으로 판매 실무에서의 경험과 전문적인 지식을 필요로하게 된다. 데이터 마이닝은 고객들에 대한 데이터의 분석을 통해서 이러한 성향들을 알아내는 것을 목표로 한다. 베이지안 네트워크는 DAG(Directed Acyclic Graph)를 이용하여 데이터의 구조를 시각적으로 표현하여 주는 확률모형으로 변수사이의 종속관계를 밝히고 데이터 마이닝의 기법으로 이용할 수 있다. 본 논문에서는 베이지안 네트워크를 사용하여 전자 상거래 고객들의 성향을 분석하기 위한 방법을 제시한다. 또한 고객성향에 대한 주요 요인을 분석하기 위해 Descriminant 모형을 이용하고 그 유용성을 다른 방법들과 비교하였다.

I. 서론

베이지안 네트워크는 데이터에 내재하는 변수와 그들의 관계를 DAG(Directed Acyclic Graph)의 형태로 노드(node)와 호(arc)를 가지고 시각적으로 나타내어 주는 모델링 방법이다. 초기에는 데이터에 대한 경험과 전문적인 지식을 이용하여 베이지안 네트워크를 표현하였으나 컴퓨터의 발달로 점차 경험과 직관에 의존하지 않고 데이터로부터 직접 베이지안 네트워크를 구성하는 것이 가능하게 되었다. 데이터로부터 베이지안 네트워크를 구성 해주기 위해서는 적절한 모델의 선

택과 국부적인 조건부 확률분포의 결정 등이 고려되어야 한다. 주어진 네트워크 구조 아래에서의 주변확률의 계산은 적절한 모델을 찾는 과정에서 특히 중요하게 된다. 특히 데이터의 일부가 숨겨져 있거나 결여되어 있는 경우, 직접적인 주변확률의 계산이 어렵기 때문에 EM (Expectation Maximization)이나 MCMC (Markov Chain Monte Carlo) 등의 간접적인 방법을 사용하게 된다. 데이터의 분류나 예측에는 Decision Tree나 신경망 모형 등이 있으나 이것으로부터 데이터의 특성이나 구조 등을 이해하는 것은 쉽지 않다. 베이지안 네트워크는 이와 같은 구

조적인 특성을 나타내는 데에 적합한 모형으로서 데이터에 대한 이해를 통하여 데이터 마이닝에 활용될 수 있다. 베이지안 네트워크를 구성하기 위해서는 중요한 요인들을 분석하는 과정이 필요하게 된다. Discriminant 모형은 범주형 결과치와 다른 변수와의 관계를 나타낸 모형으로 KDD 데이터의 전처리 방법으로 사용하였고 Decision Tree 와 Factor Analysis 에 의한 방법과 그 분석결과를 비교하였다.

II. KDD 웹데이터

KDD Cup 2000 데이터는 밸에 관련된 용품들을 취급하는 회사(Gazelle.com)에서 일정 기간(2000.1.30 ~ 2000.3.30)에 걸쳐서 그 회사를 인터넷상으로 접속한 방문자들의 실지 기록에 기초한 데이터들이다. KDD Cup 2000 데이터는 단순히 웹을 통하여 홈페이지를 방문한 경우(clickstream)와 웹을 이용하여 물건을 구입한 경우(purchase transactions)로 이루어져 있다. 적절한 Mining을 통한 웹 데이터의 분석결과는 앞으로의 영업방침이나 마케팅에서의 의사결정에서 비용과 시간을 절감하여 경제적이고 효율적인 경영에 이바지할 수 있다. 여기서는 웹을 이용하여 물건을 구입한 고객 중에서 일정금액(\$12) 이상을 구입한 고객들의 성향을 분석하는 것을 목표로 한다. KDD 데이터의 구성은 1782명에 대하여 나이, 성별, 수입, 자녀의 수, 웹을 방문한 시간, 횟수 등을 기록한 465 개의 항목으로 이루어져 있다. 이러한 변수들을 그대로 사용할 경우 결과의 해석에 있어서 불필요하게 복잡하고 계산상으로 많은 오차를 수반하므로 분석하기에 편하고 의미 있는 변수들로 바꾸어 주는 전처리 작업이 필요하게 된다. 여기서는 데이터의 전처리 방법으로 Discriminant 모델을 사용하여 6개의 요인을 사용하였고 그 결과를 Decision Tree에 의한 선택과 비교하였다. (표 1 참조)

III. 베이지안 네트워크

변수들간의 관계를 고려해서 데이터의 구조를 그래프로 나타내고자 할 때는 DAG(Directed Acyclic Graph)를 이용한 베이지안 네트워크를 이용할 수 있다. 베이지안 네트워크의 이점으로는 (1) 결측치가 많이 포함된 데이터를 자연스럽게 처리할 수 있고

(2) 성분들 간의 인과관계를 알려줌으로써 특정 조건 아래에서 결과를 예측 할 수 있도록 하여준다. 또한 (3) 인과관계의 분석에서 선형적 지식(prior)을 충분히 활용 할 수 있고 (4) 데이터를 나눌 필요가 없으므로 overfitting 을 줄일 수 있다.

N 개의 case를 가진 데이터 D 에서 n 개의 성분으로 구성된 case $\mathbf{X} = \{X_1, \dots, X_n\}$ 에 대한 베이지안 네트워크는 \mathbf{X} 의 각 성분들 간의 종속적 조건들을 정해주는 네트워크 구조 S 와 각 성분들에 대한 주변확률 P 로 이루어져 있다. 각 노드를 변수로 하고 $Pa(\mathbf{X})$ 를 변수 X_i 의 부모 쪽 노드로 표시하면 데이터의 분포는 네트워크 구조 S 에 따른 주변확률들의 곱으로서 나타내어지게 된다.

$$P(\mathbf{X}) = \prod_{i=1}^n P(X_i | Pa(X_i)).$$

먼저 X 가 단일 변수이고 r 개의 범주 x^1, \dots, x^r 를 가질 경우 X 는 multinomial 분포를 따르게 되어 $X \sim MN(\theta_1, \dots, \theta_r)$ 이된다. 즉 $\theta_k = P(x^k | (\theta_1, \dots, \theta_r))$ 의 관계가 성립한다. 모수 $\boldsymbol{\theta} = (\theta_1, \dots, \theta_r)$ 의 분포는 X 에 대한 conjugate prior 분포인 Dirichlet 분포로서 $\boldsymbol{\theta} \sim Dir(\alpha_1, \dots, \alpha_r)$ 로 주어진다. (여기서 $E[\theta_i] = \frac{\alpha_i}{\sum_{i=1}^r \alpha_i}$ 이고,

α_i 는 prior 분포를 구성하기 위한 가상적인 뜻수로 볼 수 있다.)

데이터 D 에서 k 번째 범주의 뜻수가 N_k 이면 새로운 case X_{N+1} 이 k 번째 범주에서 판측될 posterior 확률은

$$P(X_{N+1} = x^k | D) =$$

$$\sum_{\theta} P(X=x^k | \theta) P(\theta | D) = \frac{\alpha_k + N_k}{\alpha + N}$$

이 된다. 또한 evidence (marginal likelihood; BDe-Score) $P(D)$ 는

$$P(D) = \frac{\Gamma(\alpha)}{\Gamma(\alpha + N)} \prod_{k=1}^r \frac{\Gamma(\alpha_k + N_k)}{\Gamma(\alpha_k)} \quad \text{가 된} \\ \text{다.}[3]$$

case $\mathbf{X} = \{X_1, \dots, X_n\}$ 가 여러 성분으로 이루어진 경우는 k, j 를 각각 변수 X_i 와 $Pa(X_i)$ 의 k 번째, j 번째 범주 라 하고 그에

다른 모수를 $\theta_S = (\theta_1, \dots, \theta_n)$, $\theta_i = ((\theta_i)_{j,k}), k=1, \dots, r_i ; j=1, \dots, q_i$ 로 표시하면 각 (i-j)쌍의 모수 $\theta_{ij} = (\theta_{ij1}, \dots, \theta_{ijr_i})$ 의 성분 $(\theta_i)_{j,k} = \theta_{ijk}$ 는 $\theta_{ijk} = P(x_i^k | pa_i^j, \Theta_i, S)$ 이 된다.

N_{ijk} 를 $Pa(X_i) = pa_i^j$ 일 때 $X_i = x^k$ 에 해당하는 (i-j)쌍의 D에서의 뜻수라 할 때 $X_i \sim MN(\theta_{ij1}, \dots, \theta_{ijr_i})$ 이 된다.

각각의 case들이 서로 독립이면

$$P(\theta_S | D) = \prod_{i=1}^n \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} \theta_{ijk}^{N_{ijk}} \text{ 이 되며 } \theta_{ij}$$

의 conjugate prior에 대하여 $\theta_{ij} | D \sim Dir(\alpha_{ij1} + N_{ij1}, \dots, \alpha_{ijr_i} + N_{ijr_i})$ 이 된다.

또한 (i-j)쌍 간의 모수의 독립성을 가정하면 X_{N+1} 의 각 성분들이 특정한 범주 내에서 판측될 확률은 $P(X_{N+1} = x_{N+1} | D, S)$

$$= E\left[\prod_{i=1}^n \theta_{ijk}\right] = \prod_{i=1}^n \frac{\alpha_{ijk} + N_{ijk}}{\alpha_{ij} + N_{ij}} \text{ 이 된다.}$$

데이터에 결측치가 있는 경우에는 MCMC의 일종인 Gibbs Sampling이나, EM 등의 방법을 이용하여 BDe-score가 계산되어 진다.

이렇게 하여 얻어진 베이지안 네트워크는 데이터의 구조적인 특징을 보여주는 reasoning system으로 의사결정이나 예측 등을 할 수 있게 하여 준다.

IV. KDD 데이터의 분석

KDD 2000 Cup 데이터는 전자 상거래 고객에 관한 여러 가지 특성들을 측정한 데이터이다. Gazelle 회사에 따르면 2000.1.30 ~ 3.30 기간동안 2월 29일부터 TV 광고와 함께 Friends Promotion(친구를 소개하면 함께 혜택을 주는 것)을 시작하였고 중간에 동록 양식이 변경되어 설문의 내용이 바뀌었다고 한다. 그 회사 판매전문가에 의하면 그 동안 웹을 통해서 물품을 구입한 고객들의 특성들 중 알려진 몇 가지는 다음과 같다.

1. 할인된 용품을 구입하는 경우, 친구를 소개하여 함께 할인 받은 경우 현저하게 구매금액이 적었다. (그림 2)

2. 보통 양말이나 운동용 양말을 자주 신는 경우, 친구나 친지들의 소개로 방문한 경우 비교적 적은 금액의 물건을 구매하는 경향이 있다.(그림 3)




그림 1: \$12 이상 구매한 고객(True)의 비율




그림 2: 친구를 소개하고 할인 받아서 구매한 고객 중에서의 고액 구매고객 비율




그림 3: 친척이나 친지의 소개로 회사를 알게된 고객 중에서의 고액 구매고객 비율

(1) 베이지안 네트워크를 구성하는 주요 변수들의 탐색

이산형의 값을 가지는 Target에 대한 변수들의 선택 방법으로서 Discriminant 모형을 이용하여 6개의 feature들을 선택하여 범주형 변수들과 함께 노드로 사용하였다. 그것과 비교하기 위하여 Decision Tree의 결과에

서 가장 영향력이 있다고 보여지는 11개의 변수들을 선택하고, 여기에 Factor Analysis를 적용하여 새로운 변수 F1-F3를 만들어서 각각에 대한 베이지안 네트워크를 찾아보았다. 각 방법들을 비교하여 보면 물건의 최소주문량(V304)과 친구의 소개에 의한 할인비율(v240) 물건의 평균무게(v368)등이 공통으로 선택되었음을 볼 수 있다. 또한 전반적인 할인비율을 나타내는 v229, v234, v237등이 Decision Tree와 Discriminant 모형에서 나타남을 알 수 있다. (표 1)

Decision Tree의 변수를 factor analysis로 줄여준 경우 변수들이 대체적으로 View에 관한 내용(F1), 할인에 관한 내용(F2), 구매력에 관한 내용(F3)으로 나누어진다.

(2) 베이지안 네트워크를 이용한 비교 및 분석

Set A(Discriminant 모델)에 의한 베이지안 네트워크에서는 v240(친구의 소개로 인한 구입률)이 구매성향을 비롯하여 v11(누구에게 듣고 구입하였는지), v368(주문한 물건의 무게), v17(거주지역), v43(주택의 가격), v19(방문 날짜), v13(이메일 선호여부)에 직접 영향을 주는 것으로 나타났다.

Set B(Decision Tree)의 경우, v304(최소 주문량)이 추가로 구매성향에 영향을 주고 v234(할인률 5 ~ 10%의 비율)이 v13(이메일 선호여부), v237(할인률 10%이상의 비율), v240(친구의 소개로 인한 구입률), v243(Order line 의 총합)등에 영향을 준다.

위의 결과에서 v240이나 v234 등이 v13, v19 등에 영향을 미치는 사실은 앞서 언급된 사실인 “Gazelle 회사에 따르면 2000.1.30

~ 3.30 기간동안 2월 29일부터 TV 광고와 함께 Friends Promotion(친구를 소개하면 함께 혜택을 주는 것)을 시작하였고”에 부합한다.

세모형 모두 앞서 언급된 사항1 (IV, 그림2 참조)을 반영하여 친구 소개에 의한 할인(V240)과 구매 물건의 할인률(V229, v234,

v237) 이 고객들의 구매성향(v312)에 직접적인 영향을 미치는 요인임을 보여준다. (그림 4 - 그림 6)

| 선택방법 | 노드 |
|--|--|
| Discriminant 모형 + 범주형 변수 (Set A) | v240(Friend) v229(Order-Average) v304(Order shipping amt. min.) v368(Weight Average) v43(Home Market Value) v377(Num account Template Views) - v11(Which DoYouWearMostFrequent) v13(SendEmail) v17(USState) v45(VehicleLifeStyle) v68(RetailActivity) v19(Date) |
| Decision Tree (Set B) | v13(SendEmail) v234(OrderItemQuantitySum%Having DiscountRange(5 . 10)) v237(OrderItemQuantitySum%Having DiscountRange(10.)) v240(Friend) v243(OrderLineQuantitySum) v245(OrderLineQuantityMaximum) v304(OrderShippingAmtMin) v324(NumLegwearProductViews) v368(Weight Average) v374(NumMainTemplateViews) v412(NumReplenishableStockViews) |
| Decision Tree + Factor Analysis (Set C) | v368(Weight Average) v243(OrderLineQuantitySum) v245(OrderLineQuantityMaximum) F1 = 0.94*V324 + 0.868*V374 + 0.898*V412 F2 = 0.829*V234 + 0.857*V240 F3 = -0.795*V237+ 0.778*V304 |

표 1 Discriminant 모형 과 Decision Tree에 의한 노드의 선택

데이터에 대한 네트워크의 likelihood 값은 네트워크의 구조와 데이터에 따라 다르며 비교가능한 값들이 표 2에 표시되었다.




그림 4: set A 로 찾은 네트워크




그림 5. set C 로 찾은 네트워크




그림 6: set B 로 찾은 네트워크.

| Node Set | likelihood forms | log likelihoods |
|----------|----------------------|-----------------|
| Set A | $P(v312 v240)$ | -516.844 |
| Set B | $P(v312 v240)$ | -516.777 |
| Set A | $P(v312 v240, v229)$ | -448.034 |
| Set B | $P(v312 v240, v234)$ | -488.953 |

표 2. 조건부 Log Likelihood 값의 비교.

V. 결론

베이지안 네트워크는 광범위한 데이터를 변수간의 관계에 따라 그래프로 표시함으로서 단순히 분류하거나 예측하는 데에서 간과할 수 있는 데이터의 특성을 이해할 수 있게 하여 준다. KDD 데이터의 경우 고객성향을 판단하고 예측하는 것 외에 각 요인들이 어떻게 관계되어서 서로간에 영향을 주는가에 대한 명확한 구조를 알 수 있게 하여 준다. 그렇지만 노드의 수가 큰 경우나 결측치를 가지는 경우 매우 많은 계산이 요구되므로 그에 따른 효율적인 알고리즘이 연구되어져야 한다. 전처리 과정은 분석방법과는 별도로 분석결과에 영향을 미치는 중요한 작업이다. 본 논문에서는 Discriminant 모형을 사용함으로서 전처리과정에서의 탐색을 일반화 규칙화해서 보다 대용량의 데이터를 처리 할 수 있는 방법으로 발전시켰다. Entropy나 비모수 함수 등을 이용하면 보다 효과적인 변수 탐색방법으로 개선될 것을 기대 할 수 있다.

Acknowledgement

본 연구는 정보통신부 대학기초과제와 BK21-IT 프로그램에 의하여 지원되었음

VI. 참고 문헌

- [1] Marco Ramoni and Paola Sebastiani. Learning Bayesian Networks from incomplete Databases, Technical Report, KMi-Tr-43, The Open University, 1997
- [2] G.F. Cooper and E. Herskovitz. A B

ayesian method for the induction of probabilistic networks from data. *Machine Learning*, 9:309–347, 1992

[3] D. Heckerman. A tutorial on learning Bayesian networks, Technical Report MSR-TR-95-06, Microsoft Research, Redmond, Washington, 1995

[4] N. Friedman, Iftach Nachman, Dana Pe'er. Learning Bayesian Network Structure from Massive Datasets: The Sparse Candidate Algorithm, UAI1999

[5] M. Fayyad, G.P. Shapiro, P. Smyth and R. Uthurusamy, Advances in Knowledge Discovery and Data Mining, MIT Press, 1996

[6] Michael I. Jordan, editor, Learning in Graphical Models, Kluwer Academic Publishers, 1999

[7] M. Berthold , David J. Hand, Intelligent Data Analysis – an Introduction, Springer, 1999