

고객만족, NPS, Bayesian Inference 및 Hidden Markov Model로 구현하는 명품구매에 관한 확률적 추적 메카니즘

(A Probabilistic Tracking Mechanism for Luxury Purchase Implemented by Hidden Markov Model, Bayesian Inference, Customer Satisfaction and Net Promoter Score)

황 선 주¹⁾, 이 정 수^{2)*}
(Hwang Sun Ju and Rhee Jung Soo)

요 약 마케팅 분야에서는 제품품질, 고객만족, 고객추천을 바탕으로 구매행동과의 영향 유무 및 상관관계를 통계적 Regression 방법으로 가설 • 검증하는 것을 주요한 연구 대상으로 하고 있다. 또한 최근에는 ASCI와 같은 고객만족지수 혹은 라이켈트의 NPS와 같은 고객추천지수를 바탕으로 실제 기업성과와 연관되는 시장 지분에 어떠한 영향을 미치는 지에 대한 통계적 분석 연구도 활발히 이루어지고 있다. 본 연구에서는 실제 고객이 매장을 방문하여, 과거 고객카드에 명품을 구매하던 구매하지 않던 간에 만족/불만족을 표시한 체인 및 고객 추천의향을 검토하여 Hidden Markov Model을 이용한 고객의 최상의 구매패턴을 분석하는 확률적 기법에 대하여 연구하는 것을 목적으로 하고 있다. 이를 바탕으로 고객만족 -> 고객추천의향 -> 고객추천행동->구매 및 재구매 체인에 대응하는 실제 소비자의 구매패턴을 고객만족과 NPS(순추천지수) 및 여러 수리통계적 이론-Hidden Markov Model, Bayesian Inference, Maximum Likelihood Estimation을 이용하여 확률적 추적 메카니즘을 구현하는 것을 목표로 한다. 제시된 목표는 인공지능을 구현하는 이론과 알고리즘을 사용하여 달성되었기에 이론적 추적 메카니즘을 여러 인공지능망 - DNN, CNN, GAN등을 사용하여 기업에서 사용할 수 있는 고객의 구매패턴 앱으로 발전시키는 것을 후속연구에서 기대한다.

핵심주제어 : 고객만족, 고객추천, 추천의향, NPS, 추천행동, 시장 지분, Hidden Markov Model, Bayesian Inference, Maximum Likelihood Estimation, 인공지능망(DNN, CNN, GAN)

Abstract The purpose of this study is to specify a probabilistic tracking mechanism for customer luxury purchase implemented by hidden Markov model, Bayesian inference, customer

* Corresponding Author : rhee@bufs.ac.kr

+ 이 논문은 2018년도 부산외국어대학교 학술연구조성비에 의해 연구되었음.

Manuscript received November 21, 2018 / revised

December 13, 2018 / accepted December 20, 2018

1) 부산외국어대학교 경영학부, 제1저자

2) 부산외국어대학교 정보보호전공, 제2저자(교신저자)

satisfaction and net promoter score. In this paper, we have designed a probabilistic model based on customer's actual data containing purchase or non-purchase states by tracking the SPC chain : customer satisfaction -> customer referral -> purchase/non-purchase. By applying hidden Markov model and Viterbi algorithm to marketing theory, we have developed the statistical model related to probability theories and have found the best purchase pattern scenario from customer's purchase records.

Key Words : Customer Satisfaction, Customer Referral, Net Promoter Score, Bayesian Inference, Hidden Markov Model, Viterbi Algorithm

1. 서 론

마케터들에게 실질적인 정보를 제공하는 SPC (Satisfaction - Profit Chain)모형을 어떻게 구성할 것인지 연구하는 것은 서비스 마케팅 분야의 하나의 목표이며, 서비스품질과 고객만족 및 재구매를 포함한 후속행동 간의 관계를 파악한 연구들은 매우 중요하다[1-5]. Kim and Ree[6]는 자신들의 연구에서 소비자의 구매행동을 6개월 이상 추적·조사한 결과, 고객만족과 고객추천 요인들과의 관계에서 고객만족 → 추천행동보다는 고객만족 → 추천의향 → 추천행동의 경로가 유효한 경로라고 주장한다. 명품의 경우에도 제품 및 서비스 품질에 만족한 고객이라도 향후 다른 고객에 대하여 직접적인 추천행동으로 연결되지 않을 수 있다는 것을 지적하였다[7]. 실제 기업성과 향상과 직접적으로 연결되는 추천행동과 밀접한 관계가 있는 요인은 고객만족보다는 추천의향이며, 고객만족이 직접적으로 추천행동으로 이어지기 보다는 이를 매개할 수 있는 추천의향 요인의 증가를 통하여 추천행동의 증가가 이어진다는 것이다.

빅데이터와 인공지능이 중심이 되는 4차 산업 환경에서는 비록 위에서 언급한 것과 같은 SPC 모형을 잘 구성하였다 할지라도, 가설적 한계를 넘어 SPC 모형에 따른 소비자의 구매패턴을 컴퓨터나 인공지능망을 이용하여 활용할 수 있는 Probabilistic Tracking Mechanism을 밝히고 구현하는 것은 보다 더 중요할 것이다.

위에서 언급한 선행연구들[6-7]에서 연구자들은 고객만족 → 추천의향 → 추천행동의 경로가

매우 유효한 경로임일 살펴보았다. 이를 바탕으로 고객만족→고객추천의향→고객추천행동→구매/재구매 체인에 대응하는 실제 소비자의 구매패턴이 확률적 현상으로 지지되는 것으로 간주하고, 주어진 데이터로부터 NPS를 포함한 추천의향이 고객만족으로부터 추천행동을 유발하여 명품을 구매하게 하는 확률적 Tracking Mechanism을 추출하고자 한다.

다른 관점을 견지하는 연구자들은 데이터로부터 가설·검증을 위한 통계적 파라메타(평균, 표준편차, 분산 등등)를 더 선호할 수도 있다. 그러나 본 논문에서는 고객의 구매행동에는 의사 결정구조가 관여하므로 의사결정의 바탕이 되는 고객만족, 추천의향과 같은 전통적 마케팅 분야의 변인들을 수치화하여 확률적 잠재 변수(Latent Variables)로 재해석하고, 이에 대응하는 Tracking Mechanism을 확률 모델로서 구현하고자 한다. 이는 데이터로부터 정보를 재해석하는 Reverse Engineering의 한 분야이며 Bayesian Inference가 주요한 도구로서 사용된다.

요약하면, 마케팅 분야에서는 제품품질, 고객만족, 고객추천을 바탕으로 구매행동과의 영향유무 및 상관관계를 통계적 Regression 방법으로 가설·검증하는 것을 주요한 연구 대상으로 하고 있다. 또한 최근에는 ASCI와 같은 고객만족지수 혹은 라이켈트의 NPS와 같은 고객추천지수를 바탕으로 실제 기업성과와 연관되는 시장 지분에 어떠한 영향을 미치는 지를 대한 통계적 분석 연구도 활발히 이루어지고 있다. 본 연구에서는 실제 고객이 매장을 방문하여, 과거 고객카드에 명품을 구매하던 구매하지 않던 간

에 만족/불만족을 표시한 체인 및 고객 추천의 향을 검토하여 Hidden Markov Model을 이용한 고객의 최상의 구매패턴을 분석하는 확률적 기법에 대하여 연구하는 것을 목적으로 하고 있다.

통계적으로 데이터로부터 명품을 구매하는 고객의 방문횟수에서 구매횟수를 추출하여 그 고객이 명품을 구매하는 확률이라 믿고 싶어 한다. 이것은 데이터의 단순한 결과적 해석으로서 예측이라 할 수 없다. 그러나 반대의 상황(Inversion of Event)에서 즉 매장을 방문한 고객이 명품에 만족한 상태라는 조건하에서 그 명품을 구매할 확률은 얼마인가? 그리고 판매원의 순간적 추천이나, 다른 고객으로 부터의 강한 추천이 이 명품을 사도록 전이하는 확률 파라메타로 작용하여 실제 명품을 구매하도록 하는 확률은 얼마일까? 이러한 예측된 확률을 판매원 및 마케터들은 알고 싶어 할 것이다. 그리고 위에서 제시한 결과적 구매확률보다 명품에 만족한 고객이 명품을 살 확률이 정말로 더 높은 것인가, 실제 추천이 이득이 되었는지 손해가 되었는지 등등을 마케터들은 알고 싶을 것이다.

본 논문에서는 실제 고객이 매장을 방문하여, 과거 고객카드에 명품을 구매하던 구매하지 않던 간에 만족/불만족을 표시한 체인을 검토하여 고객의 구매패턴을 분석하는 기법을 소개하고자 한다. 고객의 구매행동으로부터 발생한 결과적이며 선행적인 구매확률로부터 오늘 매장에 들어온 고객의 만족 정도를 파악하여 실제로 구매로 이어지게 하는 확률적 Tracking Mechanism이 있다면 판매원과 마케터들은 행복할 것이다.

문제를 더욱 구체화하기 위해, 다음과 같은 고객만족도 체인을 가지는 소비자의 경우를 살펴보자: 만족-> 만족-> 불만족-> 불만족-> 불만족-> 만족.

위의 고객만족도 체인에서 예상되는 최상의 구매패턴 시나리오는 무엇일까? 즉 Maximum Likelihood Estimation을 활용하여 구매할 확률, 그리고 비구매할 확률과 그것에 대응하는 구매패턴 시나리오를 완성하는 문제이다. 물론 제품에 만족했다고 하여 구매만 한다고 생각하면 정확한 시나리오가 아닐 것이다. Maximum

Likelihood Estimation을 이용하는 위의 예제는 본론 2.4절에서 해결될 것이다. 보다 세밀한 문제설정은 본론 2.4절에서 다시 구성한다.

2. 본 론

2.1 고객만족과 고객추천

SPC모형에서 고객만족은 고객충성도를 이끄는 가장 중요한 변인 중에 하나로 연구되고 있다[8-11]. 또한 최근의 연구에서는 고객만족과 고객충성도 측정을 위한 여러 측정 설문문항을 개발하여 기업매출 및 시장 지분(Market Share)을 포함한 기업성과에 미치는 요인들을 보다 세부적으로 연구하고 있다[12-13]. Morgan and Rego[13]는 고객 후속행위의 측정(Measures of Customer Feedback)방법으로서 미시간 대학의 국가품질연구소(NQRC; National Quality Research Center)에서 제공받은 ACSI (American Customer Satisfaction Index), COMPUSTAT와 CRSP자료(1994~2000년)를 분석하여 고객충성도를 측정하는 후속행위측정치(Customer Feedback Metric)로서 재구매의사(Repurchase Likelihood)와 WOM (Word of Mouth) Behavior와 연계된 구전추천 횟수를 주요한 요인으로 보고 있다. 또한 Doorn et. al.[12]과 Morgan and Rego[13]은 재구매의사를 Zeithaml et al.[14]의 Loyalty Intension으로 바꾸어 기업성과에 미치는 영향요인들에 대하여 연구하였다. 특히 구매 시 충분한 정보를 갖추지 못한 경우 Katz and Lazarsfeld[15]는 구전 커뮤니케이션(구전추천)이 다른 정보 차원보다 더 큰 영향을 미친다고 주장하여 중요성을 강조하고 있다[16-17]. 이러한 고객추천의 기존 연구를 바탕으로 Kim and Ree[6]은 고객추천을 추천의향과 추천행동으로 나누어 고객만족과 고객추천의 영향관계에 관하여 실증적으로 분석하였으며, 본 연구자들은 이를 바탕으로 직접적인 구매 행위가 확률적으로 구성되는 방식을 추론할 것이다.

다수의 선행연구에서는 제품 및 서비스품질의 수준이 높을수록, 해당 기업에 대한 고객의

긍정적 태도(고객만족)가 증가하게 되며, 이러한 고객만족은 보다 높은 고객충성도를 나타나게 됨을 보여주고 있으며 이는 구매의도 및 구매행동을 유발하게 한다[1,18]. 구매한 제품에 대해 부정적인 소비자는 동일한 제품을 다시는 구매하지 않을 것이며 동시에 다른 사람에게 추천하지 않을 것이다. 그러므로 고객만족과 고객추천은 서비스 경험 후 고객구매행동을 예측하기 위한 핵심 잠재 변수로 간주되며 고객의 필요와 기대에 부응하여 그 결과로서 제품이나 서비스의 재구입이 이루어지는 개념이라 할 수 있다 [19,20].

본 논문에서는 고객만족 설문 문항을 다음절에 나오는 Hidden Markov Model의 Emission Probability Vector에 적용하기 위해 아래와 같은 증강된 고객만족 설문으로 수정하여 사용한다:

- (1) 구매한 명품의 전반적인 품질(제품 및 서비스 품질)에 만족한다.
- (2) 비구매한 명품이지만 전반적인 품질(제품 및 서비스 품질)에 만족한다.

2.2 수정 NPS(Modified Net Promoter Score)

주지하다시피, NPS(Net Promoter Score: 순추천지수)는 배인 and 컴퍼니(Bain and Company)의 Frederick F. Reichheld가 Harvard Business Review(2003, 12)에 발표한 새로운 고객충성도 측정법이다[21,22]. NPS를 측정하는 방법은 “거래하시는 회사를 친구나 동료에게 추천할 의향이 얼마나 있습니까?(How likely is it that you would recommend Company X to a friend or colleague?)”라는 추천 의향을 묻는 문항을 11점 척도로 측정하여 추천 고객(Promoter : 10점, 9점 응답자)비율에서 비추천 고객(Detractor : 6점~0점 응답자)비율을 뺀다. 국가간의 비교 문화 연구에서 문화적 차이가 Survey 응답률에 영향을 미친다는 것은 이미 오래 전부터 알려진 사실이다. 동일한 문항을 동일한 척도를 이용하여 여러 국가에서 Survey를 실시해보면 국가마다 응답 성향이 다르다. 예를 들어,

브라질의 경우 낙천적인 국민성으로 인해 응답에 후한 성향을 보인다. 이런 국가에서는 9점, 10점이 아니라 10점 응답만이 추천 고객일 수 있다. 반면, 중국과 한국은 인색하게 평가하는 성향이 있다. 이런 성향을 감안한다면 8점 혹은 7점을 준 고객까지도 추천 고객으로 정의하는 것이 더 적절한 구분일 수도 있을 것이다. 추천의향 정도에 따라 고객을 일괄적으로 구분할 수 없는 문제는 비단 국가에만 국한되지 않으며 업종별로, 고객별로도 이런 문제가 제기될 수 있다. 따라서 하나의 기준을 가지고 획일적으로 구분하고 일괄적으로 적용하는 것은 적절치 않을 수 있다. KMAC(한국능률협회컨설팅)은 2007년 이래로 11년째 “고객이 가장 추천하는 기업(KNPS)”이란 보고서를 발행하고 있으며, 이 보고서에서 NPS 점수 측도를 리커드의 7점 측도로 만들어 한국식 NPS Survey 설문에 사용되고 있다. 아래의 수정 NPS 문항도 KNPS(Korean Net Promoter Score)와 같이 한국식 7점 측도를 기준으로 한다.

라이켈트도 인정하였듯이 NPS가 모든 산업에서 기업의 성장을 예측할 수 있는 가장 좋은 지표는 아니다. 그가 NPS와 기업 성장간의 상관관계를 분석한 12개 산업 중 일부는 기업 성장과 유의미한 상관관계가 없었다. 프레드 라이켈트의 저서 The Ultimate Question(2006)에서도 어떤 B2B사업의 경우에는 “How likely is it that you will continue to purchase products or services from Company X?”가 훨씬 더 좋을 수 있다고 언급하고 있다. 재구매에 대한 추천의향을 적극적으로 묻고 있다. 그러므로 본 논문에서는 추천의향과 추천행동을 포함하는 고객추천을 다음 절에 언급되는 Hidden Markov Model의 Transition Probability Matrix에 적용하기 위해, 라이켈트의 NPS 설문 문항을 추천경로가 전이되는 수정 NPS 설문 문항으로 아래와 같이 전환하여 사용할 것이다 :

기존 프레드 라이켈트의 NPS 문항

- 1. How likely is it that you would recommend Company X to a friend or colleague?
- 2. How likely is it that you will continue to

purchase products or services from Company X?

수정 NPS 문항

1. X 회사(제품)를 이용한 고객으로서 재구매할 경우, 이 회사(제품)를 어느 정도로 다시 추천하시겠습니까?
2. 타회사(제품)를 이용한 고객(이탈고객)으로서 X 회사(제품)와 비교한 후 어느 정도로 X 회사를 추천하시겠습니까?

주지하다시피 위의 설문은 구매의사뿐만 아니라, 추천정도를 묻고 있으며 이는 향후 추천추이확률을 실증적으로 계산하는 도구가 된다.

2.3 Hidden Markov Model과 Viterbi 알고리즘

Keiningham et al.[23]의 공동 연구에서 프레드 라이켈트가 수행한 것과 동일한 방법으로 NPS를 대신해 ACSI를 프레드 라이켈트가 NPS와 기업 성장 지표 간의 상관관계가 있다고 예시로 사용했던 산업(항공업, PC, 미국 생명보험업, 인터넷 서비스)과 기업 성장 지표를 비교해보면 놀라울 정도로 유사한 결과를 보이며, ACSI 역시 기업 성장과 뚜렷한 상관관계를 보이고, 어떤 산업에서는 오히려 NPS 보다 더 강한 상관관계를 보이고 있다고 주장한다. 결론적으로 NPS만이 기업의 성장과 상관관계를 보이는 유일한 지표는 아니며 고객 만족도 보다 더 우월하다고 할 수 없다[24]. 실제로는 고객만족과 NPS가 서로 경쟁적으로 기업성장 지표와 구매행동에 영향을 주고 있는 것으로 추측된다. 그러므로 본 논문에서는 2.1에서 소개된 증강된 고객만족과 2.2에서 소개된 수정 NPS 고객추천으로 부터 Hidden Markov Model의 Emission Probability Vector와 Transition Probability Matrix로 각각 대응하여, 이러한 것들이 구매확률에 어떤 방식으로 관여하는 지를 파악할 것이다.

언제나 대두되는 문제 중의 하나로서, 발표된 마케팅 문헌이나 시장조사관련문헌에서 Survey를 통해 측정된 고객의 구매의향은 실제 구매행

위와는 차이가 있다는 것을 간과할 수 없다[24]. 동일한 논리로, Survey 데이터인 추천의향에 대한 측정치와 실제 구매행위에 대한 관찰치와는 엄연히 다르다. 실제로 국내 어느 서비스 업종에서 실행한 고객만족조사로부터 얻은 데이터에서 추천의향과 구매행동과의 관계를 살펴보면, 구체적으로 추천의향이 있거나 높은 고객 중 약 36.6%가 지속사용 (또는 반복구매)을 하지 않고 이탈했다는 것을 알 수 있다. 이는 추천의향이 높은 고객도 얼마든지 실제로는 구매 및 재구매하지 않고 떠날 수 있다는 것을 보여주고 있다 [24].

위에서 언급한 현상들은 Survey 데이터와 실제 데이터와의 확률적 비교분석을 유도하는 Tracking Mechanism의 개발의 필요성을 야기한다. 언급된 데로 고객추천과 구매행동에서 발생하는 개념적 갭을 줄이고, 고객만족과 NPS가 상생적으로 기업성장 및 구매행동에 영향을 주도록 Pay-Off하게 하는 Bayesian Inference는 하나의 유효한 Scheme이 될 것이다. 본 논문에서는 Hidden Markov Model을 이용한 Bayesian Inference를 논문의 기술적 하부 Scheme으로 채택한다. 그러므로 추천의향 및 구매의향으로부터 구매패턴을 확률적으로 예측하는 Tracking Mechanism의 근간으로 Hidden Markov Model과 Bayesian Inference를 선택한다. 그리고 기업측면에서도 추천의향을 추천행동 및 구매행동으로 연결되도록 하는 보상책을 강구해야한다[25]. 실제로 고객만족 및 NPS가 신뢰도 측면에서 성공적으로 관리되려면, 고객만족 및 고객추천으로부터 구매로 이어지는 경로를 추적하여 측정하고 관리할 수 있는 확률적 Tracking Mechanism으로 보장 되어야 할 것이다. 본 논문에서 언급하는 확률적 Tracking Mechanism이라는 개념은 주어진 데이터(빅데이터)로부터 재해석할 수 있는 다양한 수리 통계적 융합 모델을 의미한다.

고객만족, 고객추천, 구매 및 재구매 이어지는 고객의 의사결정구조에서 고객추천은 '의사 결정 과정의 편의성'을 보장한다. 소비자들은 구매행위를 위한 의사결정 과정에서 복잡하거나 정교한 정보보다는 단순하거나 도식화 되어 있는

정보에 더 크게 의존하는 경향이 있다. 복잡한 환경에 적응하기 위해서 모든 사안에 대해 정보 처리 과정을 거치기보다는 자동화된 행동 양식이 의사 결정에 더욱 효율적이기 때문이다. 이는 A. Tversky와 D. Kahneman의 휴리스틱스(Heuristics) 추론이론에 기인한다. 추천에 의한 정보는 객관적인 정보에 비해 상대적으로 덜 교류할 수는 있으나 기억 및 인출이 쉽고 인지적인 노력을 더 적게 요구한다. 따라서 고객들의 정보 탐색 과정을 줄여주고 의사 결정을 용이하게 하여 정보처리 상의 과부하를 피할 수 있는 고객추천 정보를 고객은 의외로 선호한다[24].

위에서도 언급하였듯이 고객만족 및 고객추천으로부터 구매행동으로 이어지는 경로를 하나의 확률론적 의사결정구조로 보는 견해에 의해 데이터를 이용한 Tracking Mechanism을 개발하는 것은 당연한 논리이다. 이는 데이터가 주는 정보를 바르게 활용하는 방법이기도 하다. 단순히 구매행동을 수요, 공급 및 욕구와 필요에 의한 소비자 행동론에 입각한 견해로만 볼 것이 아니라, 구매행동을 고객의 의사결정구조로 보는 것이 그 동안의 경영학적 마케팅 지식을 빅 데이터를 포함한 통계적 데이터 사이언스로 전이하도록 하는 바탕이 되며, Survey Data와 실제 데이터 간의 개념적 갭의 발생을 해석해 주는 도구를 개발하게 한다[26]. 이미 인공지능 소프트웨어들은 이를 시행하고 있으며 여러 면에서 인간의 능력을 초월하고 있다. 사실 컴퓨터의 소프트웨어가 인간에 의한 유도 또는 비유도 학습을 스스로 수행하여 필요한 모델을 개발하는 추세에 있다.

본 절에서는 2.1에서 언급한 증강된 고객만족과 2.2에서 언급한 수정 NPS를 Hidden Markov Model의 마진확률 측정치 즉 Emission Probability Vector와 Transition Probability Matrix로 변환하여, 실증적 데이터를 수리통계 모형으로 모델링하여 고객의 구매패턴에 대한 베스트 시나리오를 만들어 주는 Viterbi 알고리즘을 소개할 것이다. 사실, Hidden Markov Model은 알파고가 사용한 것으로 유명한 몬테카를로 모델, Bayesian Inference과 함께 인공지능 연구의 추축이 되는 이론이다[27-31].

2.4 문제설정 및 a Solution Kit

명품 매장을 방문한 고객이 언제나 만족한 쇼핑을 하는 것은 아니다. 고객은 명품을 구입하고 만족한(Satisfied) 경우도 있고, 불만족한(Not Satisfied) 경우도 있다. 실제 명품을 구매했지만 마음에 들지 않았을 경우 혹은 구매하지 못하였지만 마음에 들었던 경우도 확률적 정보로 이용할 것이다.

다음은 본 연구자들이 주목하고자 하는 문제로써 아래에 상세히 기술한다 :

1. 매장을 방문한 고객이 제품에 대해 만족한 상태라는 조건하에서 그 명품을 구매할 확률은 고객의 일반적 구매확률보다 높은가?
2. 고객이 만족->불만족 체인을 표출하였다면, 고객의 베스트 명품 구매패턴은 무엇인가?
3. 만족-> 만족-> 불만족-> 불만족-> 불만족-> 만족 이라는 고객만족도 체인에서 예상되는 베스트 구매패턴 시나리오는 무엇인가?

2.4.1 Emission Probability Vector

고객의 만족과 불만족 정도는 관찰자에 의한 고객의 Emission Probability Vector로 재가공할 수 있는 기반이 된다. 이로부터 연구자들은 실제 구매패턴을 추정할 수 있게 되는 것이다. 텔레커뮤니케이션(전화 Survey 등)에 의한 고객만족의 정도를 만족과 불만족으로 구분한 Emission Probability Vector의 예를 살펴보자.

아래의 Fig. 1은 명품 구매 및 비구매에 대응하는 고객만족 텔레커뮤니케이션 모델이다:




Fig. 1 Hidden Emission State

즉 위의 모형은 구매 후 엘리스의 만족 정도는 80% : 20%로 Marginal Probability가 형성되고 있다는 것을 말해주고 있다. 구매에 있어서 80% 정도는 만족하지만 20% 정도는 그 구매에 대해 만족하지 못하는 전반적 만족 상태를 확률로 표현한 것이다. 실제 매장을 방문해온 고객의 구매상태와 고객만족도가 Table 1과 같이 표출된 경우, 위에서 언급한 고객만족도에 관한 확률적 계산을 아래와 같은 방법으로 적용한다.

아래의 Table 1에서 구매(P)->만족(S)으로 표출되는 상대도수가 8번이고, 구매(P)->불만족(NS)으로 표출되는 상대도수는 2번이다. 그러므로 총 구매회수 10번 중에서

구매(P)->만족(S) : $8/10 = 0.8 = 80\%$

구매(P)->불만족(NS) : $2/10 = 0.2 = 20\%$

로서 데이터와의 비교 관찰에 의한 Emission Probability를 파악할 수 있다. 구매한 상태에서의 고객만족도의 표출인 (0.8,0.2)는 Marginal Probability Vector로서, 이를 고객만족을 표출하는 Emission Probability Vector 라고 한다. 마찬가지로 비구매 상태에서의 총 비구매 회수 5번 중에서

비구매(NP) ->만족(S) : $2/5 = 0.4 = 40\%$

비구매(NP) ->불만족(NS) : $3/5 = 0.6 = 60\%$

로서, (0.4,0.6)이 Emission Probability Vector가 된다. 물론 제품 구매 후 만족 정도를 묻는 설문은 2.1 고객만족 설문문항 “(1)구매한 명품의 전반적인 품질(제품 및 서비스 품질)에 만족한다” 따르고, 제품 비구매 후 만족 정도를 묻는 설문은 2.1 고객만족 설문문항 “(2)비구매한 명품이지만 전반적인 품질(제품 및 서비스 품질)에 만족한다”을 적용한다. 그리고 각 설문의 샘플 집단 기준으로 만족정도의 상대도수를 측정하면 표와 같은 형태의 고객만족 체인을 만들

수 있다. 즉 Grouped Data에서는 고객만족의 평균을 Emission probability을 구하는 기준으로 사용하여, 위에서 언급한 경우와 같은 각 개인의 고객만족도 체인뿐만 아니라 Grouped Data에 대한 Emission Probability Vector를 구성할 수 있다.

Fig. 1은 Hidden Emission State로서 구매/비구매 후 고객만족의 정도를 표출한 관계를 그림으로 나타낸 것으로서, Emission Probability Vector는 다음 절에서 설명하는 Markov Chain의 Transition Probability Matrix와 결합하여 Hidden Markov Model을 형성하고, 구매행위의 의사결정구조에 계산상 영향을 미치는 Static State가 된다. 물론 은닉(Hidden) 이라고 불리는 이유는 고객만족이라는 Static State와 다음 절 2.4.2에서 언급하는 Transition Probability Matrix를 만드는 수정 NPS 추천의향이 구매/비구매 후 확률로 표현되는 감추어진 값들이며, 실제 구매 확률에 영향을 주는 Latent Variable이 되기 때문이다.

2.4.2 Transition Probability Matrix

Dynamic State인 구매행위를 설명하기 위해서는 고객추천이란 전이 상태가 먼저 확률로서 전제되어야만 한다. 고객추천은 고객의 의사결정구조에서 ‘의사 결정 과정의 편의성’을 보장하고 소비자들의 정보 탐색 과정을 줄여주고 의사결정을 용이하게 하여 정보처리 상의 과부하를 피할 수 있게 하므로 소비자들이 선호한다고 언급하였다. 실제 SNS상에서는 고객의 의사 결정 구조에 영향을 주도록 수많은 추천 앱이 생산되고 있다. 이러한 우수 추천 앱이 입소문을 타고 번지기 시작하면 제품 브랜드의 시장 지분에 상당한 변화를 주고 있기에 기업과 점주들은 유명

Table 1 Purchase Chain and Emitted Customer Satisfaction Chain

Purchase Chain	P	P	P	P	NP	NP	NP	P	P	P	P	NP	NP	P	P
Customer Satisfaction	NS	S	S	S	NS	NS	S	NS	S	S	S	NS	S	S	S

추천 앱에 거액의 광고료를 주고 자사의 제품을 홍보하고 있다. 즉 SNS 상의 추천은 구매행위와 바로 직결되기 때문이다. Markov의 이론에 의하여 현재의 시장 지분으로부터 목표 시장 지분으로 수렴하게 하는 것이 Transition Probability Matrix이고, 시장 지분 계산에서 주로 Markov Process를 활용하고 있다. 사실 목표 시장 지분은 이탈되지 않은 고객의 재추천과 이탈된 고객의 새로운 추천 즉 추천 Transition Probability Matrix가 일정기간 유지됨으로서 점진적 확률프로세스에 의해 지분이 형성된다는 것이 Markov의 이론이다.

Grouped Data에서는 본 연구자들의 수정 NPS 설문 문항- “X 회사(제품)를 이용한 고객으로서 재구매를 할 경우, 이 회사(제품)를 어느 정도로 다시 추천하시겠습니까?” -으로 부터 이탈되지 않은 고객의 재추천 추이확률을 구한다. 수정 NPS 설문문항으로 구한 재추천 추이확률이 0.8 이라면 추천하지 않을 확률은 0.2가 되어 (0.8, 0.2)는 Marginal Probability로서 추천 Transition Probability Matrix의 첫 번째 행이 된다. 수정 NPS 설문 문항- “타회사(제품)를 이용한 고객(이탈고객)으로서 X 회사(제품)와 비교한 후 어느 정도로 X 회사를 추천하시겠습니까?” -으로 부터 이탈된 고객의 추천확률이 0.4라면, 이탈된 고객으로부터 추천되지 않을 확률은 0.6이 되어 (0.4,0.6)은 Marginal Probability로서 Transition Probability Matrix의 두 번째 행이 된다. 그러므로 수정 NPS에 의한 Transition Probability Matrix는

$$\begin{pmatrix} \text{이용고객 재추천확률, 이용고객 비추천확률} \\ \text{이탈고객 추천확률, 이탈고객 비추천확률} \end{pmatrix} = \begin{pmatrix} 0.8, 0.2 \\ 0.4, 0.6 \end{pmatrix}$$

이 된다. 또한 고객의 Ungrouped Data 에서 기록된 실제 구매이력이 아래와 같은 경우 즉, 구매,구매,구매,구매,비구매,비구매,비구매,구매,구매,구매,구매,비구매,비구매,구매,구매,구매로 구매패턴이 구성된다면 Transition Probability Matrix를 다음과 같이 구할 수 있다 :

구매->구매 (8번) : 8/10 = 0.8 = 80%
 구매->비구매 (2번) : 2/10 = 0.2 = 20%

비구매 ->구매 (2번) : 2/5 = 0.4 = 40%
 비구매 ->비구매 (3번) : 3/5 = 0.6 = 60%
 이므로 Transition probability Matrix는 $\begin{pmatrix} 0.8, 0.2 \\ 0.4, 0.6 \end{pmatrix}$ 이 된다. Transition probability Matrix를 Transition Diagram으로 표시하면 아래의 Fig. 2와 같다 :




Fig. 2 Transition Diagram of Transition Probability Matrix

2.4.3 Hidden Markov Model

마케터들은 판매원과 달리 고객의 만족도와 추천의향을 분석하여 판단할 뿐이지 고객이 명품을 구매했는지, 구매하지 않았는지는 실증적으로 확인해보지 않고서는 알 수 없다. 마케터들이 이용할 수 있도록 연구자들은 고객의 축적된 구매데이터를 분석하고 고객 만족도와 추천의향을 설문하여 Hidden Markov Model에 적용할 확률적 정보로서 저장한다. 그러므로 고객의 결과론적인 실제 구매/비구매 행동의 후속 행위로서, 고객만족 및 추천의향은 아래 Fig. 3과 같은 수리 통계적 모델인 Hidden Markov Model로 형성된다:

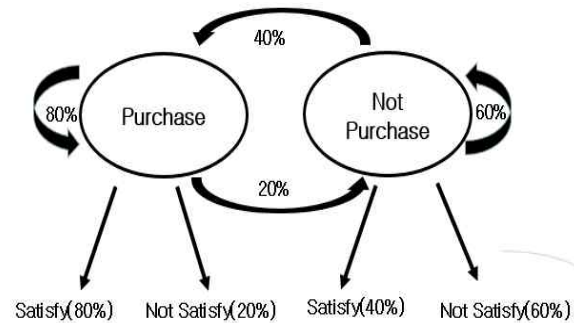


Fig. 3 Hidden Markov Model

고객의 구매의도를 만족/불만족의 Emission Probability로서 측정할 뿐만 아니라, 고객에게 질문된 수정 NPS는 시장 지분에 영향을 미치는 Transition Probability Matrix를 구성하는 추천의향 상대도수로 사용될 수 있다. 고객만족도와 실제 추천의향은 조사하지 않은 이상 표현되지 않기에 고객만족과 추천의향은 본질적으로 감추어진 잠재적인 확률변수이다. 이 감추어진 상태들이 설문 조사의 확률로서 표현될 수 있으므로, Hidden Markov Model은 고객만족의 정도를 관찰에 의한 확률로 나타난 Emission Probability Vector와 고객추천으로부터의 Transition Probability Matrix로 구성될 수 있다. 이러한 Hidden Markov Model은 Fig. 3과 같이 Transition Diagram으로 표시된다. 특히 Transition Diagram은 튜링의 유한상태 오토마를 연상하게 한다.

2.4.4 Markov Process, Bayesian Inference와 Viterbi 알고리즘

이제는 주어진 문제를 해결할 차례이다. 명품 매장을 방문한 고객이 어떤 의견(만족도나 추천의도)도 내지 않고 제품을 살펴볼 때, 랜덤 상태로 구매할 확률 $P(p)$, $p = \text{purchase}$ 혹은 비구매할 확률 $P(np)$, $np = \text{not purchase}$ 을 어떻게 계산해야 할까? 랜덤 고객이 명품 매장을 방문할 경우, 구매 확률 및 비구매 확률을 알 수 있다면 마케터들에게는 많은 도움이 될 것이다. 그 동안 고객관리 차원에서 모아놓은 고객만족도 및 추천의향 데이터를 Hidden Markov Model로 가공했다면 아래와 같이 원하는 확률들에 대한 수치를 파악할 수 있다.

Transition Probability Matrix로부터 Markov Process에 의한 구매확률 $P(p)$ 은 재추천확률 0.8 및 이탈된 고객이 새롭게 추천한 확률 0.4로부터 결정되고, 비구매확률 $P(np)$ 은 재추천하지 않을 확률 0.2와 이탈된 고객들이 새로이 추천하지 않을 확률 0.6에 의해 결정된다. 이를 요약한 것을 수식으로 표현하면 아래와 같다 :

구매 확률 :

$$P(p) = 0.8P(p) + 0.4P(np)$$

비구매확률 :

$$P(np) = 0.2P(p) + 0.6P(np) \quad \dots \quad (*)$$

마진 확률 조건 :

$$P(p) + P(np) = 1$$

물론 위의 요약된 식으로 성립되기 까지는 Transition Probability Matrix가 일정한 시기까지 유지되고, 다음 상태는 현재 상태에만 의존하고 변화하는 Markov Property를 따르는 경우, 목표 시장 지분이 Markov Process에 의해 결정된다[30]. 시장은 단순한 현상이 아니다. 시장은 동적이던, 카오스적이던 점진적 확률과정을 포함하고 있다고 연구자들은 보고 있다. 그러한 시장을 표현하는 한 가지 방법이 시장 상태확률인 Steady State Probability가 Markov Process를 따른다는 것이다. 자세히 설명하면, n 단계 경과 후의 시장상태확률 값은 아래의 귀납적 구조로 표현된다:

$$\begin{aligned} (P_1^n, P_2^n) &= (P_1^{n-1}, P_2^{n-1}) \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix} \\ &= (P_1^{n-2}, P_2^{n-2}) \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix}^2 \\ &\dots \\ &= (P_1^0, P_2^0) \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix}^n, \end{aligned}$$

요약하면, $(P_1^n, P_2^n) = (P_1^0, P_2^0) \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix}^n$ 으로 표현된다[30,32]. 여기서 P_1^n, P_2^n 은 n 단계 경과 후의 상태확률 값으로 $P_1^n + P_2^n = 1$ 이다. 마찬가지로 P_1^0, P_2^0 은 초기단계의 상태확률 값으로 $P_1^0 + P_2^0 = 1$ 이다. 그리고 $\begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix}$ 는 주어진 Transition Probability Matrix로서, 이렇게 단계들이 수없이 경과 한 후 시장상태확률로 수렴된다. 이 확률적 계산은 고유값-고유벡터 분해 방법으로 Transition Probability Matrix가 $\begin{pmatrix} 0.8 & 0.2 \\ 0.4 & 0.6 \end{pmatrix}$ 인 경우, 위와 같은 식 (*)로 귀결된다.

위의 주어진 방정식을 풀어 보면 구매확률

$P(p) = 2/3$ 이고 비구매 확률 $P(np) = 1/3$ 이 된다. 그러므로 설문조사에 의한 고객추천 Transition Probability가 0.8로 높은 상태이지만, 실제 구매확률은 2/3로서 점진적 확률과정인 Markov Process에 의해 수정된다. 이에 본문 2.3에서 언급된 것과 같이 발표된 마케팅 문헌이나 시장조사관련 문헌에서 Survey를 통해 측정된 고객의 구매의향은 실제 구매행위와는 차이가 있다는 실증적 조사가 Markov Process에 의해 수리 확률론적으로 확인된다. LG 경제연구원[24]에서 지적한 것과 같이, 추천의향이 있거나 높은 고객 중 약 36.6%가 지속사용 또는 반복구매를 하지 않고 이탈했다고 단순히 단정할 것이 아니라, 추천의향은 구매행위가 아니므로 의사결정에 있어 수정이 빈번하며, 수리적으로 Markov Process와 같은 점진적 확률 상태를 거쳐 추천의향이 구매행위로 전이한다는 사실을 본 논문은 입증하고 있음을 주지하기 바란다.

사실 처음 방문한 고객에 관한 정보는 주어지지 않으므로, 고객이 방문한 명품 매장이 다른 명품 매장에 비해 차지하는 비중 즉 시장 지분이라고 하는 데 보통은 축적된 통계 데이터에 의해 구매확률로 알려져 있다. 일반적으로 시장 지분은 Transition Probability Matrix에 의한 Markov Process를 적용하여 위에서 언급한 바와 같이 재해석하고 있다[28,29]. 그러므로 처음 방문한 고객도 일반적 시장 구매확률을 가지게 되는 것이다.

위와 같이 Hidden Markov Model에 내재되어 있는 모든 확률적 정보를 Prior Probability(선행 확률)이라고 부른다. 이를 상세히 기술하면 다음과 같다 :

- A. 고객이 구매한 조건하에서 명품에 대해 만족할 확률 : $P(s|p) = 0.8$
- B. 고객이 구매한 조건하에서 명품에 대해 불만족할 확률 : $P(ns|p) = 0.2$
- C. 고객이 비구매한 조건하에서 명품에 대해 만족할 확률 : $P(s|np) = 0.4$
- D. 고객이 비구매한 조건하에서 명품에 대해 불만족할 확률 : $P(ns|np) = 0.6$
- E. Transition Probability Matrix :

$$\begin{pmatrix} \text{이용고객 재추천확률, 이용고객 비추천확률} \\ \text{이탈고객 추천확률, 이탈고객 비추천확률} \end{pmatrix} = \begin{pmatrix} 0.8, 0.2 \\ 0.4, 0.6 \end{pmatrix}$$

F. Transition Probability Matrix로부터 Markov Process를 수행하여 얻은 시장 지분 확률:

명품을 구매할 확률 $P(p)$

명품을 비구매할 확률 $P(np)$

단, $s = \text{satisfy}$, $ns = \text{not satisfy}$ 를 의미한다.

위의 Hidden Markov Model에 내재된 선행 확률들을 이용하여 첫 번째 문제를 해결하여 보자. 즉 고객이 명품에 만족한 조건하에서 명품을 구매할 확률 $P(p|s)$ 을 먼저 구해보자 :

베이지의 정리에 의해

$$\begin{aligned} P(p|s) &= \frac{P(p \cap s)}{P(s)} \\ &= \frac{P(p) \cdot P(s|p)}{P(p \cap s) + P(np \cap s)} \\ &= \frac{P(p) \cdot P(s|p)}{P(p) \cdot P(s|p) + P(np) \cdot P(s|np)} \\ &= \frac{(2/3) \cdot 0.8}{(2/3) \cdot 0.8 + (1/3) \cdot 0.4} \\ &= 0.8 \end{aligned}$$

이 성립한다. 동일한 베이지안 추론으로 고객이 명품에 만족한 조건하에서 비구매할 확률은 $P(np|s) = 0.2$ 로 계산된다. 이러한 확률들을 선행 확률을 사용하여 계산한 확률이라 Posterior Probability라고 한다. 위에서 본 것과 같이 고객이 만족한 상황에서 명품을 구매할 확률 $P(p|s) = 0.8$ 은 Transition Probability Matrix로 Markov Process에 의해 구한 시장 지분 확률 즉, 랜덤상태인 시장에서의 일반적인 구매확률 $P(p) = 2/3$ 보다 더 높아져 있다는 사실이 수리 통계적 모델의 도구인 Bayesian Inference로 확인된다. 그러므로 문제설정 1번 질문-매장을 방문한 고객이 제품에 대해 만족한 상태라는 조건하에서 그 명품을 구매할 확률은 고객의 일반적 구매확률보다 높은가? -에 대한 해답은 Positive이다. 실제 시장을 확률과정으로 보고 있는 통계학적 측면에서 기본적으로 마케팅 부분의 경험적 견해, 즉 고객만족이 강하면 고객 충성도가 높아지고 구매로 이어진다는 실증적 분석을 추구하는 마케팅 부분의 경험적 이론을 뒷받침하기 위해서 Hidden Markov Model을 적

용한 경우에는 수리통계적으로 위의 질문 문항이 증명되어야 한다. 그래야만 본 연구자들이 채택하고 있는 수리 통계적 모델이 마케팅 분야에 적용 가능한 모델로서의 기반을 갖추기 때문이다. 조금 더 정확히 서술하면 아래와 같은 정리를 얻는다:

정리 1. 먼저 $P(p)$ 를 Hidden Markov Model의 Transition Probability Matrix로부터 Markov Process를 수행하여 얻은 명품 시장에서 고객이 명품을 구매할 확률 즉 시장 지분 확률이라 정의한다.

매장을 방문한 고객이 제품에 대해 만족한 상태라는 조건하에서 명품을 구매할 확률 $P(p|s)$ 이 고객이 시장에서 명품을 구매할 시장 지분 확률 $P(p)$ 보다 같거나 클 필요충분조건은 명품을 구매한 조건하에서 고객이 만족할 확률 $P(s|p)$ 이 비구매한 조건하에서 고객이 만족할 확률 $P(s|np)$ 보다 같거나 클 경우이다.

즉, $P(p|s) \geq P(p)$ if and only if $P(s|p) \geq P(s|np)$ 이다.

증명: $P(p|s) \geq P(p)$ 이 성립할 필요충분조건을 추적하여 증명할 것이다. 즉

$P(p|s) \geq P(p)$ if and only if $P(p|s) - P(p) \geq 0$
 \Rightarrow 조건확률의 정의 의해, $P(p|s) - P(p) \geq 0$

$$\text{if and only if } \frac{P(s \cap p)}{P(s)} - P(p) \geq 0$$

$\Rightarrow \frac{P(s \cap p)}{P(s)} - P(p) \geq 0$ if and only if

$$P(s \cap p) - P(s)P(p) \geq 0$$

\Rightarrow 베이저 정리에 의해,

$$P(s \cap p) - P(s)P(p) \geq 0 \text{ if and only if}$$

$$P(s|p) - P(s) \geq 0$$

$\Rightarrow P(s|p) - P(s) \geq 0$ if and only if

$$P(s|p)[1 - P(p)] - P(np)P(s|np) \geq 0$$

$\Rightarrow P(s|p)[1 - P(p)] - P(np)P(s|np) \geq 0$

$$\text{if and only if } P(s|p) - P(s|np) \geq 0$$

그러므로 $P(p|s) \geq P(p)$ if and only if $P(s|p) - P(s|np) \geq 0$ 이 성립되어 증명이 완성된다.

다음은 문제설정 2번 질문-고객이 만족->불만족 체인을 표출하였다면, 고객의 베스트 명품

구매패턴은 무엇인가? -에 대한 베스트 구매패턴을 확률로 계산하여 찾는 방법이다. 만약 고객이 만족->불만족 이라는 고객만족도 체인을 갖는다면 실제 구매패턴은 다음의 4가지 중에서 한 가지 일 것이다, 즉 구매-> 구매 ; 구매-> 비구매 ; 비구매-> 구매 ; 비구매-> 비구매의 4가지 시나리오를 점검해서 가장 일어날 법한 고객의 구매패턴을 수리통계적 모델로 찾으려고 한다. 이처럼 발생확률이 가장 높은 패턴을 결정하는 것을 Maximum Likelihood Estimation 이라고 한다. 물론 실제 주어진 고객의 만족도에 대한 구매기록을 확인하여 답을 낼 수도 있으나, 이는 결과론적 구매기록이지 수리통계모델로 패턴을 예측하는 것과는 거리가 멀며, 구매패턴 Tracking Mechanism을 밝히는 것은 더 더욱 아니다. 실제로 마케터들은 고객의 만족도를 알고 있을 뿐이지 고객이 명품을 구매했는지 혹은 구매하지 않았는지는 실증적으로 확인해보지 않고서는 알 수 없다. 그러나 우리는 축적된 데이터를 이용해서 가장 일어날 법한 고객의 구매패턴을 수리모델을 이용하여 탐지하고자 한다.

A. 구매->구매 case :

이 경우에는 구매하고 만족한 경우의 확률과 다음번에 다시 구매하고 불만족한 경우의 곱에 해당하므로 $P(p)P(s|p)$ (이용고객 재추천 확률) $P(ns|p) = (2/3)(0.8)(0.8)(0.2) \approx 0.08576$ 이다.

B. 구매->비구매 case :

이 경우에는 구매하고 만족한 경우의 확률과 다음번에 비구매하고 불만족한 경우의 곱에 해당하므로 $P(p)P(s|p)$ (이용고객 비추천 확률) $P(ns|np) = (2/3)(0.8)(0.2)(0.6) \approx 0.06432$ 이다.

C. 비구매->구매 case :

이 경우에는 비구매하고 만족한 경우의 확률과 다음번에 구매하고 불만족한 경우의 곱에 해당하므로 $P(np)P(s|np)$ (이탈고객 추천확률) $P(ns|p) = (1/3)(0.4)(0.4)(0.2) \approx 0.01056$ 이다.

D. 비구매->비구매 case :

이 경우에는 비구매하고 만족한 경우의 확률과 다음번에 비구매하고 불만족한 경우의 곱에 해당하므로 $P(np)P(s|np)$ (이탈고객 비추천확률) $P(ns|np) = (1/3)(0.4)(0.6)(0.6) \approx 0.04752$ 이다.

결론적으로, 위의 4가지 시나리오 중에서 가장 확률적으로 일어날 법(the most likely to happen)한 구매패턴은 Hidden Markov Model과 Maximum Likelihood Estimation에 의해 구매->구매 인 경우이다.

좀 더 나아가서, 만약 고객의 만족도 정도가 연속적으로 만족->불만족->만족 체인으로 구성된다면 단순히 고객이 구매->비구매->구매했다고 추론하기에는 수리통계적으로 부적절하다. 물론 구매하지 않을 경우라도 얼마든지 우리는 제품에 대하여 만족할 수 있기 때문이다. 그러므로 수리통계적 추론에 의해 구매패턴을 추적하는 메카니즘을 얻기 위해, 위에서 적용한 아이디어를 확장하려고 한다. 만약 고객의 만족 체인이 만족->만족->불만족->...->만족 체인으로 그 길이가 n 이라면 가능한 시나리오의 개수는 2^n 이 되고 여기에 해당하는 모든 확률을 계산하여 Maximize 하는 구매패턴을 찾아야 하므로 n 이 커지면 실제 구매고객 만족 체인은 산술급수적으로 증가 하지만 시나리오의 개수는 기하급수적으로 증가 즉 Exponentially Increase 하므로 비용과 계산상 문제가 발생한다. 이 문제를 피하는 여러 방법이 있지만, 기본적으로 관찰한 Emission Probability Vector와 Transition Probability Matrix로 구성된 Hidden Markov Model을 이용하여 Maximum Likelihood Estimation를 수행하는 Viterbi 알고리즘을 본 논문은 채택하고 그 내용을 간단한 구매 패턴 계산으로 아래의 3번 질문에서 소개한다:

문제설정 3번 질문 -만족->만족->불만족->불만족->불만족->만족 이라는 고객만족도 체인에서 예상되는 베스트 구매패턴 시나리오의 무엇일까?-을 Viterbi 알고리즘으로 고객만족도 체인에 대응하는 베스트 구매패턴을 찾기 위해 귀납적으로 계산한 결과를 Table 2로 작성하고 Viterbi 알고리즘을 설명하는 계산과정을 아래에서 설명한다.

고객만족도 체인에서 만약 첫 단계에서 고객이 만족했다면, 고객이 명품을 구매하고 만족한 확률과 명품을 구매하지 않았지만 만족한 확률을 계산할 수 있다. 즉 명품을 구매하고 만족한

확률은 $P(p)P(s|p)=(2/3)(0.8) \approx 0.533$ 이고, 명품을 구매하지 않았지만 만족한 확률은 $P(np)P(s|np)=(1/3)(0.4) \approx 0.133$ 으로서, 첫 번째 열에 기록된다. 첫 번째 구매하고 만족한 것에 이어 두 번째로 구매하고 만족하는 확률 즉 (첫번째 구매->만족 대응확률)(이용고객 재추천 확률) $P(s|p)=P(p)P(s|p)$ (이용고객 재추천 확률) $P(s|p)=(0.533)(0.8)(0.8) \approx 0.341$ 과 첫 번째 비구매하고 만족한데 이어 두 번째로 구매하고 만족하는 확률 즉 (첫번째 비구매->만족 대응확률)(이탈고객 추천확률) $P(s|p)=P(np)P(s|np)$ (이탈고객 추천확률) $P(s|p)=(0.133)(0.4)(0.8) = 0.04256$ 을 비교하여 큰 값 0.341을 선택한 구매패턴을 두 번째 단계의 구매 대응확률과 함께 Table 2에 기록한다. 위와 동일한 방법으로, 첫 번째 구매하고 만족한데 이어 두 번째 비구매하고 만족한 확률 $(0.533)(0.2)(0.4) \approx 0.043$ 와 첫 번째 비구매하고 만족한데 이어 두 번째로 비구매하고 만족할 확률 $(0.133)(0.6)(0.4)=0.03192$ 과 비교하여 큰 값 0.043을 선택하여 두 번째 단계의 비구매 대응확률로 Table 2에 기록한다. 같은 방식을 귀납적으로 수행하면 위의 표가 완성되고 연구자들은 베스트 구매패턴 -구매->구매->구매->비구매->비구매->구매-시나리오를 찾을 수 있다.

사실 Viterbi 알고리즘은 Cantor의 Diagonalized Zig-Zag Scan처럼 Dyadic Calculation을 단계별로 진행하고 그 결과 확률 값이 큰 것을 채택하고, Emission Probability와 Transition Probability를 귀납적으로 집적하여 Table 2와 같은 베스트 시나리오를 구성하는 Scheme이다.

이로서 연구자들은 서론에서 질문한 3가지 문제를 모두 해결하였다. 결론에서는 이를 요약 정리하고 후속연구에 필요한 시사점들을 제언할 것이다.

3. 결론

제품을 구매한 후 고객은 간단한 설문에 대한 응답으로 구매에 대한 고객만족 내지 고객추천

Table 2 Best Purchase Patten corresponding to Customer Satisfaction Chain

Customer Satisfaction	satisfy	satisfy	not satisfy	not satisfy	not satisfy	satisfy
Purchase Pattern1	purchase	purchase	purchase	purchase	purchase	purchase
Corresponding Probability1	0.533	0.341	0.0546	0.0087	0.0014	0.0017
Purchase Pattern2	not purchase	not purchase	not purchase	not purchase	not purchase	not purchase
Corresponding Probability2	0.133	0.043	0.041	0.0147	0.0053	0.0013
Best Purchase Pattern	purchase (0.533)	purchase (0.341)	purchase (0.0546)	not purchase (0.0147)	not purchase (0.0053)	purchase (0.0017)

의 정도를 나타낼 수 있다. 연구자들은 이런 구매 후 고객의 후속행위를 증강된 고객만족 설문 문항과 수정 NPS 설문문항으로 정형화하였다. 이를 바탕으로 증강된 고객만족 설문문항을 이용하여 Emission Probability Vector와 수정 NPS 설문문항으로 Transition Probability Matrix를 구성하여 Hidden Markov Model을 형성하였다. 즉 고객의 구매 후 고객만족 및 고객 추천을 포함한 후속행위에 의해 표출되고 전이된 의향 및 의도는 데이터 분석 결과로 Hidden Markov Model의 확률요인으로 작용하고, Markov Process에 의하여 발생된 Prior Probability들과 융합하여 Posterior Probability로 계산되어 서론에서 질문한 구체적인 세 가지 문항에 대하여 Bayesian Inference을 이용한 Solution을 제공하였다. 자세한 계산과정은 2.4.4 Markov Process, Bayesian inference와 Viterbi 알고리즘 부분을 참조하기 바란다. 요약하면, 본 연구에서는 실제 고객이 매장을 방문하여, 과거 고객카드에 명품을 구매하던 구매하지 않던 간에 만족/불만족을 표시한 체인을 검토하여 고객의 구매패턴을 분석하는 기법- 확률적 Tracking Mechanism을 소개하고 있다. 본 연구의 앞으로의 목적과 기대효과를 구체적으로 제시하기 위해 여러 측면에서 시사점들을 살펴볼 것이다:

1. 4차 산업의 꽃인 인공지능 시대가 본격적

으로 확장되는 순간에 우리는 살고 있다. 스티브 잡스의 텔레커뮤니케이션 모바일 혁명은 그의 소원 테로 시장 또는 은행을 휴대폰 안에 장착시켰고, 고객만족 및 고객추천 댓글에 의해 기업의 성과가 시장 지분으로 곧바로 전환되는 인터넷 환경에서 생활하고 있다. 고전적으로 기반 데이터로 사용되는 고객만족 및 추천의향 설문과 고객의 구매활동을 분석하여 고객의 최상 구매패턴 시나리오를 수리통계적 모형으로 제시한 것은 인공 지능을 이용한 정보과학 분야에서 다양한 시도를 할 수 있는 좋은 사례가 될 것이며, 지능형정보사회에서 필요한 융합 학문 분야의 학문적 발전에 유용한 자료와 근거를 제공할 수 있을 것으로 사료된다.

2. 전통적인 마케팅 분야에서는 제품품질, 고객만족, 고객추천을 바탕으로 구매행동과의 영향 유무 및 상관관계를 통계적 Regression 방법으로 가설 • 검증하는 것을 주요한 연구 대상으로 하고 있다. 또한 최근에는 ASCI와 같은 고객만족지수 혹은 라이켈트의 NPS와 같은 고객추천지수를 바탕으로 실제 기업성과와 연관되는 시장 지분에 어떠한 영향을 미치는 지를 대한 통계적 분석 연구도 활발히 이루어지고 있다. 위에서도 언급하였듯이 실제 고객이 매장을 방문하여, 과거 고객카드에 명품을 구매하던 구매하지 않던 간에 만족/불만족을 표시한 체인 및

추천의향을 검토하여 Hidden Markov Model을 이용한 고객의 구매패턴을 분석하는 확률적 기법에 대하여 본 논문은 연구하고 있다. 이러한 종류의 수리통계적 모델이 활발히 연구되어, 실제적으로 고객만족도와 추천의향이 가설·검증 단계를 뛰어넘어 구매행동에 확률변수로서의 직접적 영향을 주고 있다는 정보를 마케터들에게 제공하기를 기대한다. Table 2에서 제시된 것과 같은 구매패턴이 밝혀지면, 매장에서 매출을 촉진하게 되는 방안을 구축하는 자료로 활용될 것이다.

3. 여러 마케팅 기존 연구에서 살펴볼 수 없었던 부분 즉 고객만족->고객추천->구매/비구매 경로에 대한 확률적 Tracking Mechanism을 본론 2.1 및 2.2에서 제시된 설문 및 고객의 구매 활동 기록을 통해 데이터를 분석하여 고객의 베스트 구매 시나리오와 함께 제시한 것은 중요한 성과라 할 것이다. 그러나 4차 산업과 인공지능은 단순한 고객만족과 추천행동에 대한 설명 이상의 것들을 제시할 수 있으며, 명품을 구매하는데 미치는 여러 상황변수들과 인과 관계에 영향을 미치는 변수들 간의 관계를 잘 설명하는 도구가 될 수도 있음을 인지하고 있다. 이는 본 논문의 한계점으로 주지하고 있으며, 차후의 연구에서는 이런 부분을 연구해 볼 것이다. 또한 고객만족, 추천의향, 구매행동에 대한 확률 계산상 분명한 영향관계가 있음을 제시한 본 논문의 베스트 시나리오가 실제 구매/비구매 활동과의 간격을 인공 지능 학습을 통해 줄여 나가는 기법을 연구하는 것을 향후 연구목표로 삼고 있다.

References

- [1] Choi, S. and Kim, D., "Relation with Hospital Quality of Service, Customer Satisfaction, Reuse," Journal of the Korea Contents Association, Vol. 10, No. 6, pp. 344-351, 2010.
- [2] Jeong, M. and Lee, G., "A Study on the Prediction of Referral Intention based on Customer Satisfaction in Construction Management," Korean Journal of Construction Engineering and Management, Vol. 11, No. 6, pp. 100-110, 2010.
- [3] Jin G. S. and Lee, J., "Service Quality Factors Affecting Satisfaction and Repurchase Intention of Social Commerce," Journal of the Korea Contents Association, Vol. 12, No. 3, pp. 311-321, 2012.
- [4] Yoon, J. and Kim, K., "A Study on the Logistics Service Quality, Customer Satisfaction and Post-purchasing Behaviors in the Internet Shopping Mall," The Journal of Information Systems, Vol. 15, No. 1, pp. 21-48, 2006.
- [5] Sun, Z. Y. and Kim, J. S., "The Relationship among the Purchasing Behavior of Luxury Brands Affecting Luxury Brands Preference and Purchasing Intention of Young Generation in China," 2009 KAMS/KSMA Fall International Conference, pp. 38-52, 2009.
- [6] Kim, K. S. and Ree, S., "Empirical Study on Customer Satisfaction and Others Factor Influencing would recommend in NPS(Net Promoter Score)-Focus on Kitchen Furniture-," Journal of the Korean Society for Quality Management, Vol. 37, No. 2, pp. 58-67, 2008.
- [7] Hwang S. J. and Kim, J. P., "The Effects of Perceived Quality on Customer Satisfaction and Recommendation in Luxury Purchases," The Journal of Professional Management, Vol. 19, No. 3, pp. 51-76. 2016.
- [8] Anderson, E. W. and Mittal, V., "Strengthening the Satisfaction-Profit Chain," Journal of Service Research, Vol. 3, No. 2, pp. 107-120, 2000.
- [9] Churchill, G. A., "A Paradigm for Developing Better Measures of Marketing Constructs," Journal of Marketing

- Research, Vol. 16, pp. 64-73, 1979.
- [10] Churchill, G. A. Jr. and Surprenant, C., "An Investigation into the Determinants of Customer Satisfaction," *Journal of Marketing Research*, Vol. 19, pp. 491-504, 1982.
- [11] Mittal, V. and Kamakura, W. A., "Satisfaction, Repurchase Intent, and Repurchase Behavior: Investigating the Moderating Effect of Customer Characteristics," *Journal of Marketing Research*, Vol. 38, No. 1, pp. 131-142, 2001.
- [12] Doorn, J. V., Leeflang, P. S. H. and Tijs, M., "Satisfaction as a Predictor of Future Performance : A Replication," *International Journal of Research in Marketing*, Vol. 30, No. 3, pp. 314-318, 2013.
- [13] Morgan, Neil A. and Rego, Lopo Leotte, "The Value of Different Customer Satisfaction and Loyalty Metrics in Predicting Business Performance," *Marketing Science*, Vol. 25, No. 5, pp. 426-439, 2006.
- [14] Zeithaml, V. A., Berry, L. and Parasuraman, A., "The Behavioral Consequences of Service Quality," *Journal of Marketing*, Vol. 60, No. 2, pp. 31-46, 1996.
- [15] Katz, E., and Lazarsfeld, P. F., *Personal Influence: The Part Played by People in the Flow of Mass Communication*, Glencoe, IL: Free Press, 1955.
- [16] Lee, Jonathan, Lee, J. H., and Feick, Lawrence, "Incorporating Word-of-Mouth Effects in Estimating Customer Lifetime Value," *Journal of Database Marketing and Customer Strategy Management*, Vol. 14, No. 1, pp. 29-39, 2006.
- [17] Song, J. T., "The Influence of Service Quality on the Customer Satisfaction, Purchase Intention and Word-of-Mouth Communication : Online In-service Teacher Training," Wonkwang University, Doctoral Thesis, 2003.
- [18] Lee, S. H., Lee, L. and Jung S., "The Effects of Variables on Fashion Luxury Brand Purching Behavior," *Journal of the Korean Society of Clothing and Textiles*, Vol. 27, No. 11, pp. 1241-1251, 2003.
- [19] Howard J. A. and Sheth J. N., *The Theory of Buyer Behaviour*, J. Wiley and Sons, New York, 1969.
- [20] Oliver R. L., "A Cognitive Model of the Antecedents and Consequences of Satisfaction Decisions," *Journal of Marketing Research*, Vol. 17, pp. 460-469, 1980.
- [21] Reichheld, F., "The One Number You need to Grow," *Harvard Business Review*, 2003.
- [22] Reichheld, F., and Markey, R., *The Ultimate Question 2.0 : How Net Promoter Companies Thrive in a Customer-Driven World(Revised and Expanded Edition)*, Harvard Business Review Press, 2011.
- [23] Keiningham, Timothy L., Cooil, B., Andreassen, Tor Wallin and Aksoy, L., "A Longitudinal Examination of Net Promoter and Firm Revenue Growth," *Journal of Marketing* Vol. 71, 2007.
- [24] Hwang, H. J. and Choi, J. H., "Effective Execution Requirements of NPS Survey," LGERI Report, LG Business Insight, 2007.
- [25] Oh, H. K., "The Influence of the Methods of the Sale of Trade in Allowances of Jewelry for the Customer's Intention for Purchase," Graduate School of Kyonggi University, Master Thesis, 2006.
- [26] Koller, D., McAllester D. and Pfeffer, A., "Effective Bayesian Inference for Stochastic Programs," *Proceedings of the Fourteenth National Conference on Artificial Intelligence*, pp. 740-747, 1997.
- [27] Bairagi, A., and Kakaty, Sarat Ch.,

“Analysis of Brand Loyalty Using Homogeneous Markov Model,” IOSR Journal of Economics and Finance, Vol. 7, No. 4, pp. 6-9, 2016.

[28] Netzer, O., Ebbes, P., and Bijmolt, T., “Hidden Markov Models in Marketing,” Springer International Series in Quantitative Marketing, Chapter XX, 2016.

[29] Netzer, O., Lattin, J. M., and Srinivasan V., “A Hidden Markov of Customer Relationship Dynamics,” Marketing Science, Vol. 27, No. 2, pp. 185-204, 2008.

[30] Park, B., Linear Algebra for 8 days Study, Ch. 6, Kyungmoon Press, 2014.

[31] Poole and Macworth, Artificial Intelligence; Foundations of Computational Agents, Chap. 6, Cambridge University Press, 2017.

[32] Jeong, S. Y., Hur, S. and Lee, H. G., “ATM Traffic Modeling with Markov Renewal Process and Performance Analysis,” KORMS Conference, pp. 1-6, 1998.



황 선 주 (Hwang Sun Ju)

- 정회원
- 부산외국어대학교 경영학부 경영학사
- 부경대학교 경영석사
- 부산외국어대학교 경영학박사
- 부산외국어대학교 경영학부 초빙교수
- 관심분야 : 서비스 마케팅, 마케팅 모델링, 글로벌 경영전략



이 정 수 (Rhee Jung Soo)

- 정회원
- 경북대학교 사범대학 수학과 이학사
- 경북대학교 대학원 수학과 이학석사
- 플로리다주립대학교 수학과 이학박사
- 부산외국어대학교 글로벌융합대학 정보보호/사이버경찰전공 교수
- 관심분야 : Harmonic Analysis, 정보보호/양자암호, 인공지능/AI보안