

## 多デバイス接触履歴からの視聴行動モデル化と知識更新

## Modeling of Trans-Device Contents Experience and Knowledge Development for TV Audience Detection

岡崎孝太郎<sup>\*1\*3</sup>

Kotaro Okazaki

井上克巳<sup>\*1\*2\*4</sup>

Katsumi Inoue

<sup>\*1</sup> 総合研究大学院大学 複合科学研究科 情報学専攻  
SOKENDAI (The Graduate University of Advanced Studies)<sup>\*2</sup> 国立情報学研究所  
National Institute of Informatics<sup>\*3</sup> 株式会社 ソナー  
SONAR Inc.<sup>\*4</sup> 東京工業大学 情報理工学院  
School of Computing, Tokyo Institute of Technology

The dramatic transition into TV viewing through smartphone has released the traditional passive mass audiences. It also may changes the paradigm in medium business since last century. This paper presents a framework for detecting audience behavior temporal patterns that the endogenous power by SNS and exogenous contact on trans-devices cause to emerge. We construct a state space representation for latent viewing attitude and extract the rules for logic programing between key variables from lifelog in the trans-devices single source data. This is a trial of AI technology to contribute the novel progress in TV business.

## 1.はじめに

視聴率調査会社が公表する世帯視聴率は、テレビ放送事業におけるカレンシーデータである。世帯視聴率は、視聴率調査会社が管理するモニター世帯に置かれた受信機が、テレビ番組の放映時間内にどれだけその番組を映し続けたかを測る。つまり視聴者による視聴履歴を番組単位で累積した数値である。今世紀に入り情報通信技術が急激にテレビ視聴を変貌させ、視聴率は媒体指標としての再現性を疑問視され始めている。各家庭の受信機を、家族が共有した状況は一変した。スマートフォンで見逃し配信を視聴できる現在、テレビは個人視聴媒体になりつつある。図1は、2016年の個人視聴と世帯視聴の推移比較である[1]。

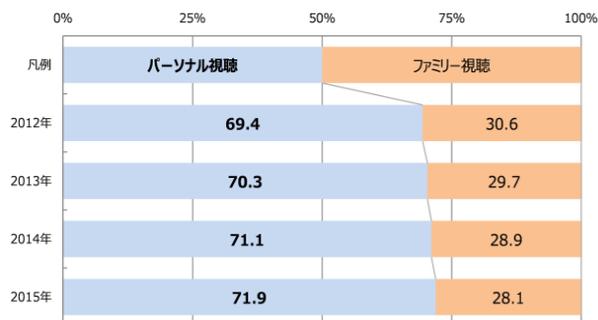


図1 6時~24時における個人視聴と世帯視聴の推移

スマートフォンからのテレビ視聴は受動体験ではない。SNSなどの交信を駆使し自ら体験を瞬時に他者と共有する。図2は、2012年と2015年におけるテレビ視聴におけるSNS連携利用の推移である[2]。その体験はさらに他者の反応や創作を加えて改変され、影響を拡大する。デバイス同士の接続が視聴者間の内生化を進めれば、世帯毎の視聴という前提は損なわれる。

随時異なるデバイス経由で体験するテレビ視聴は即ち、定時一斉視聴からの解放である。昨今の高視聴率番組は、SNSや動画像共有を介した話題拡散を人気の起爆力と見做しているが、現象を明らかにした研究は殆どない。受信デバイスを跨ぐ視聴履歴の裏に潜む、潜在的な態度の可視化。視聴促進につながる外生要因の制御可能性。これが本研究の問いである。

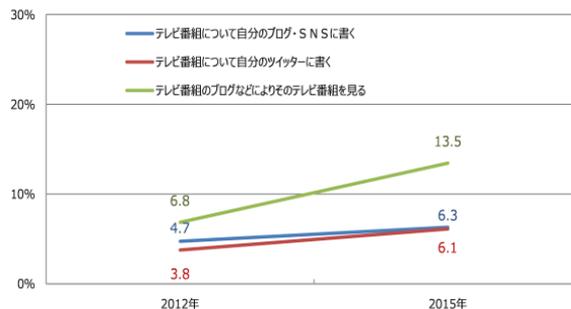


図2 テレビ視聴とSNSの連携利用の推移

媒体やデバイスを跨ぐ視聴特徴の抽出と、抽出した特徴に介在する視聴態度モデルは何か、モデルを駆動させる作用や規則は何か、それらを知識化できるか、新たな知識から未知の仮説を得られるか。本研究ではこうした探究に対して、同一コンテンツに纏わる複合的な視聴履歴を捉えた調査データに、自然言語処理、ニューラルネットワーク、自動推論分野の人工知能技術を適用する。視聴態度を表す特徴量を示すデータシーケンスから状態空間モデルを推定し、制約や規則を知識として抽出する。クロスメディアを前提としたテレビ放送の新たな意義を見極め、マーケティングコミュニケーションの革新につなげる。

## 2.本研究に関連する知識

以下、本論を理解する上で必要なテレビ放送の概念や、適用する人工知能技術を解説する。

<sup>\*3</sup> 東京都中央区銀座 8-16-6 2F, okazaki@sonar01.co.jp

## 2.1 視聴率調査

日本の放送エリアは全 32 あり、視聴率調査はそれぞれの放送エリアごとに、全国 27 地区の調査エリアにおいて、調査対象世帯のテレビに測定機を設置し、機械式による調査を実施している。調査対象世帯は、ランダムサンプリングの手法のひとつである系統抽出法で選ばれる。調査世帯数は、関東地区で 900 世帯、関西地区、名古屋地区で 600 世帯、それ以外の調査地区は 200 世帯であり、二～三年間で全世帯が入れ替わる。

## 2.2 世帯視聴率

世帯視聴率は、何世帯がその放送局のチャンネルをつけていたかという割合をパーセント表示したものである。データの最小単位は 1 分ごとの毎分視聴率で、平均視聴率は、この毎分視聴率をもとに算出する。放送時間が 19:00-19:59 の番組 A の平均視聴率の算出方法は、19:00 から 19:59 までの 60 時点の毎分視聴率を合計し、放送分数の 60 で割ったものである。

## 2.3 VR CUBIC

VR CUBIC は、ビデオリサーチがテレビとネットの接触を機械で測定しているシングルソースパネルである。インターネット利用者を母集団とした関東一都 6 県 15～69 歳男女 5,000 サンプルを対象に、同一サンプルからテレビ視聴と PC、スマートデバイスによるネット接触、アプリ利用をログベースで取得している為、デバイスを跨いだリーチや重複を把握することができる。

## 2.4 自己符号化器

自己符号化器は、入力情報の次元を縮減する、入力層、中間層、出力層の 3 層からなるニューラルネットワークである。入力層と出力層に同一データを与えて学習させるため、圧縮後に元のパターンへ復元できる。学習中の誤差逆伝播法が過剰適合しないような中間層の増設により、性能を劇的に向上させるアルゴリズムを、2006 年にヒントンらが提案した[3]。

## 2.5 隠れマルコフモデル

隠れマルコフモデル[4]は、背後に状態系列が潜在して、表面の事象系列のみが観測される世界を表わす有向巡回グラフ構造の確率モデルである。確率変数  $x(t)$  は、時刻  $t$  の観測事象  $y(t)$  の確率分布である。時刻  $t$  の潜在変数  $x(t)$  の条件付き確率は、潜在変数  $x(t-1)$  にのみ依存する。

## 2.6 解釈遷移からの学習

解釈遷移からの学習[5]は、観測事象の時系列から、事象間の論理規則を割り出すアルゴリズムである。動的な状態空間内の時刻  $t$  における状態  $I$  を時刻  $t+1$  における状態  $J$  へ遷移させる演算  $T_p(I)$  について、空間内に検出される全ての  $T_p$  が同時に成立させる命題論理式へと帰納的に縮約させていく。最終的には論理的に同値な、離散時間を引数とした一階述語論理の知識表現に変換される。動的な大規模システムにおける意思決定プロセスへ適用できる人工知能技術として注目を集めている。

## 2.7 ブーリアンネットワーク

ブーリアンネットワーク[6]は、各ノードの値が 0 か 1 のバイナリ表現をとり、エッジからノードへの入次規則とノード毎に割り当てられたブール関数によって、ネットワーク全体が同期

的に遷移するグラフィカルな論理モデルである。ノードを命題変数と見做せば、ノードとエッジの組み合わせを論理包含性から命題論理式へ変換でき、状態空間はブールベクトルとして表現できる。

## 3. 研究の方法

### 3.1 対象番組

2016 年に放送されたテレビドラマの中で、放送が好評を博し、コンテンツが社会現象にまでなった番組 N を解析対象とする。各回視聴率を番組 N 対同枠過去平均と比較した図 3 を参照すると、内容の質の高さの差を他としても、視聴率を急激に押し上げる現象を探るには最も適している[7]。

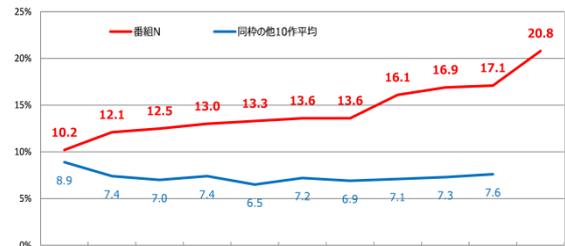


図 3 番組 N の各回視聴率の時系列推移

### 3.2 変数の定義とデータの取得

視聴者が放送時に視聴したかを目標変数とする。次に仮説の構築に寄与しそうな観測可能な変数を定義する(表 1)。視聴者の内生性や外因的な情報接触からの視聴態度の変容は、その回の視聴有無と次回の視聴有無との差分比較から 4 象限設定した。調査サンプルは、VR CUBIC で番組 N の放送期間に履歴を取得できた 3,256 名である。定義した変数の有無を判別記録したデータを解析する。

x00	オンエア視聴差分	無視
x01	オンエア視聴差分	流入
x10	オンエア視聴差分	離脱
x11	オンエア視聴差分	継続
n02	前番組 (マツコの知らない世界) からの視聴	
n03	本編のダイジェスト・再放送を視聴	
n04	タイムシフト視聴	
n05	見逃し配信	
n06	予告やダイジェスト動画を見た	
n07	出演者が踊る「恋ダンス」動画接触	
n08	出演者以外の有名人・一般視聴者が踊る「恋ダンス」動画	
n09	番組TVCMへの接触	
n10	情報番組などでの紹介・ゲスト出演の視聴	
n11	Yahoo! ニュースなどのニュースサイト、まとめサイトなど	
n12	TBS公式ホームページへのインプレッション	
n13	Twitterでの行動 関連キーワードのポスト、ハッシュタグのRT等	
n14	Facebookでの行動 フィードでの投稿、関連ニュースや動画のシェア等	

表 1 設定された観測変数の一覧

### 3.3 離散化

シングルソースデータは、複数の変数がどう同期、作用しているかを個人の一貫した行動履歴として取得できる。変数に割り当てるインスタンスの時系列を離散化する。放送開始時刻から遡る前週の同時刻から、今回開始 1 分前までの一週間を 1 期とし、全放送回と告知週を併せた 12 期の時系列とする。データは各期  $t$  において視聴者個々人の、番組 N のその回の放送以降一週間に渡る番組に関連した様々な外因的な情報への接触の有無を記録する。次に履歴の有無を真偽値として各変数へブール値が割り当てられる。発現可能

なベクトルの全パターンは、2 の 17 乗 131,072 通りである。この各パターンを 17 桁の 2 進数と捉えて 10 進数へ変換する。この 10 進数をパターンの識別初期 ID として割り当てる。

### 3.4 目標特徴のフラグ化と解析サンプル

全サンプル 3,256 名の行動履歴 12 期分の延べセル数は 39,072 である。ここに 131,072 種類の行動パターンが視聴態度として分布している。この全セル内の識別初期 ID からヒストグラムを生成する。そこから潜在ディリクレ配分法(以下 LDA と略す) [8]を使って全行動パターンの潜在意味を割り出し、意味の仮説への寄与率が高い順に該当する行動パターンを再リスト化する。意味特性を両極とした特徴評価軸で行動パターンを評価し、識別 ID を振り直す。

### 3.5 サンプルデータの画像化

1 期以内でのパターンに対し、識別 ID の昇順に沿ってグレースケール諧調を当てると。行動特性が一方の極に寄れば白、他方に寄れば黒で表現される。グリッド数 12 のグレースケール画像シーケンスとなった視聴パターンをニューラルネットワークへ入力する。

### 3.6 時系列特徴

期内行動パターンを複数種類に集約した、全 2,522 名分の 12 期を通した行動履歴データを、2,522 枚の 3×4 グレースケール画像として自己符号化器へ入力し、学習させる。学習完了後、中間層の全ノードに固有に発現する結合重みの配列をクラスタリングし、同一クラスターに属するノードが活性化する元画像集合を、そのクラスターに紐づける。各クラスター内の元画像集合が得られた時系列特徴の可視化に相当する。

### 3.7 状態空間モデル

クラスター内各サンプル毎のデータを、観測値が行動パターンの種類数分の放出をもつ、12 期に渡る隠れマルコフモデルの観測系列とみなし、クラスターが示す時系列特徴が潜在する状態空間モデルを推定する。クラスターの時系列特徴が発現するメカニズムは、潜在変数の数と初期確率、変数間の遷移確率、観測状態の放出確率に表れる。

### 3.8 論理規則の学習

クラスター内サンプルの行動履歴から、元の 12 期に渡った変数 17 次元の時系列ブールベクトルを得る。これを観測状態の入力とし解釈遷移からの学習を行う。学習はクラスター毎に固有の論理規則集合が割り出されるまで続けられる。最終的には、17 変数間のブーリアンネットワークを出力する。ここでクラスターの時系列特徴を発現させる 17 の各変数同士の因果関係が明示される。

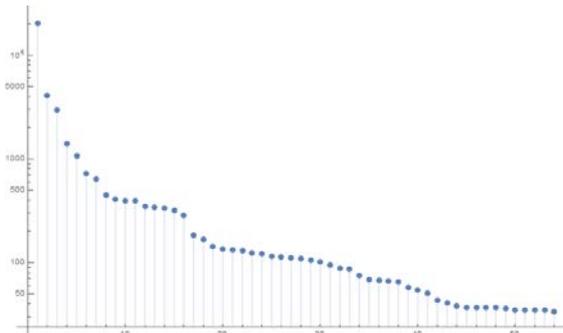


図 4 期内視聴パターンの発現ヒストグラム

これらの整式は、帰納論理プログラミング[9]における背景知識や解集合プログラミング[10]などの高度な自動推論ソルバーのためのプログラムとして適用できる。

## 4.解析結果

全サンプルの行動履歴 12 期分の行動パターンのヒストグラムが図 4 である。縦軸は対数尺度である。突出した最大度数の行動パターンは、「期中に一切番組 N 関連の情報と関わっていない」を表す視聴者である。これを除いた次点「番組 N に何らか関わった行動パターン」から 53 位までの行動パターンを発現した、合計 2,522 名分のサンプルデータを解析対象とした。これで「番組 N に何らか関わった行動パターン」を採った視聴者行全体の約 92% について説明できる。

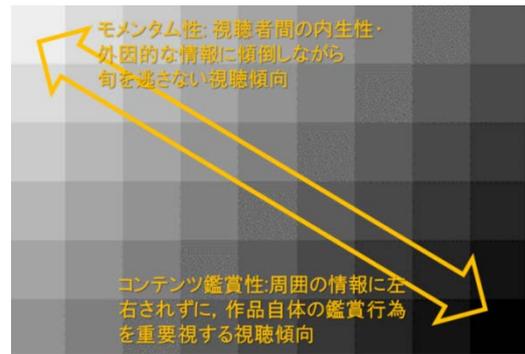


図 5 期内行動パターンの特徴評価軸と諧調の割り当て

予告週	初回週	第二回週	第三回週
第四回週	第五回週	第六回週	第七回週
第八回週	第九回週	第十回週	最終回週

図 6-1 時系列特徴諧調表現と放送回の対照

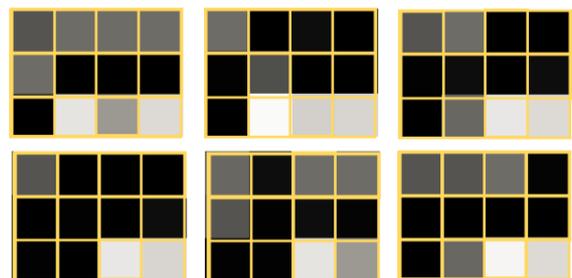


図 6-2 クラスター No.2 に帰属するサンプルのパターン例

今回の課題に貢献するように、LDA により抽出した潜在意味群から評価軸を設定した(図 5)。一方はモメンタム性すなわち番組 N を取り巻く時勢や旬が行動に影響して、放送のオンエア時視聴に価値をおく極。他方の極はコンテンツ鑑賞性すなわちオンエア番組内容自体にのみ視聴意義を見出し、派生した副次的なコンテンツや情報に無関心な態度である。グレースケール諧調では、モメンタム性に寄れば白、コンテンツ鑑賞性に寄れ

ば黒として可視化される。学習された自己符号化器の中間層に発現する時系列特徴を 32 クラスに分割した結果から、クラス No.2 に紐づくサンプルの視聴パターン例を示す。図 6-1 より、左上のグリッドが予告週、順次右下のグリッドへ、放送回が進むにつれてパターンが遷移する様子を捉えている(図 5 を参照)。図 6-2 のクラス No.2 は、放送序盤では関心外だが、中盤からタイムシフト視聴で視聴習慣が定着し、終盤には話題性に乗ってオンエア視聴へと変化するパターンと解釈できる。

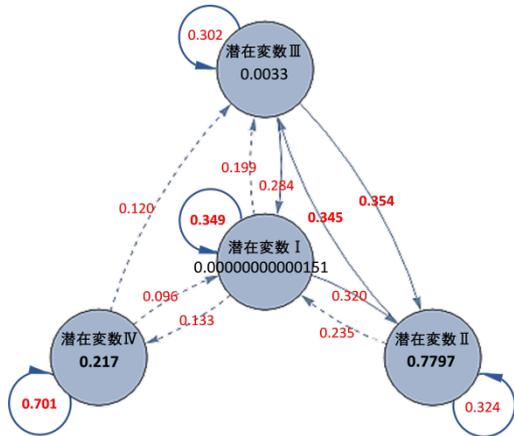


図 7 クラス No.2 の隠れマルコフモデル

時系列特徴クラスタについて、紐づくサンプルの行動パターンから計算した隠れマルコフモデルを図 7 に示す。ノードは潜在変数を示し 4 状態として初期確率および状態間の遷移確率を図内に表現している。クラス No.2 では、潜在状態 II から次第に III に遷移する動きと IV が維持される様相が示されている。放出確率の高いパターンを照合すると、話題や宣伝に敏感に反応する状態からモメンタムにさらに乗りつつ、視聴習慣は安定しく望ましい性質である。図 6 での時系列特徴は、こうした潜在視聴態度の確率的な遷移から発現すると思われる。

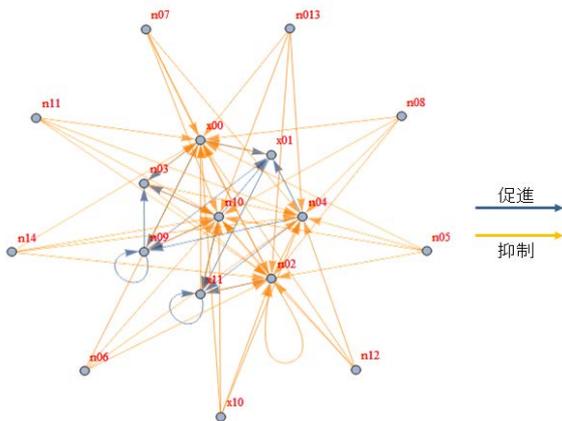


図 8 クラス No.2 から学習した論理ネットワーク

次に、時系列特徴から得られる論理規則を図示した。解釈遷移からの学習で生成される論理式のアトムをグラフ化し、変数同士のリンクにおける作用を可視化する。ノード毎に推定されたブール関数の値域における真偽率に影響度と見做して、これに反するリンクを枝刈りした結果が図 8 の論理ネットワークである。解釈例としては、x01 は x00 から生起し、x11 や n02 などへ視

聴態度を導く。一旦視聴流入が起きると前番組からの流れからの準備行動や安定した視聴習慣に繋がるという内容を示唆している。かくして変数同士の論理規則がブーリアンネットワークで表されることにより、さらに規則の非対称性、k 次マルコフ過程=遅延効果などの研究も視野が開ける。

## 5.検討と今後へ向けて

以上から番組視聴における時系列特徴を、可視化されたパターンと、特徴を駆動させる状態空間モデルと、変数間の論理規則を組み合わせて検討できる。外因的な世の中の話題性の勢い、全放送回の何回目にヤマ場があったか、特別番組など放送局の編成努力、さらに視聴者の生活スタイルなどが複合して、潜在変数である視聴態度が生まれ、この潜在状態は放送回が進むにつれて、特徴的な時系列遷移を起こすことが判る。

かくして本研究で記号的推論と特徴抽出を統合した実世界へ適用する技術フレームワークについて一例を示せたとと思う。テレビ放送における新しい視聴態度の抽出と、媒体クラスを跨ぐ時系列の視聴特徴の抽出も実現した。モデル化によってシミュレーション、予測を可能になり、知識の抜き出しによってその背後の状態空間と背景知識との関連付けから仮説構築へ、より高度な推論の可能性への道筋もついたと考える。特定コンテンツに関連した異なる媒体施策の実施シーケンスを示すトリップデータがあればさらに精緻な仮説がたてられ、プランニング精度の向上につながるだろう。

## 謝辞

サンプルデータの準備、その他解析作業にご協力頂いた(株)ビデオリサーチの長島秀樹氏、小木真氏、榎屋裕三氏、河辺昌之氏 諸氏に、謹んで感謝の意を表する。

## 参考文献

- [1] ビデオリサーチ: 関東地区視聴率調査, (2016).
- [2] ビデオリサーチ: テレビ総合調査, (2015).
- [3] Hinton, Geoffrey E., and Ruslan R. Salakhutdinov.: "Reducing the dimensionality of data with neural networks.", science 313.5786, (2006).
- [4] Baum, Leonard E., and Ted Petrie.: "Statistical inference for probabilistic functions of finite state Markov chains.", The annals of mathematical statistics 37.6, (1966).
- [5] Inoue, Katsumi, Tony Ribeiro, and Chiaki Sakama.: "Learning from interpretation transition." Machine Learning 94.1 (2014).
- [6] Kauffman, Stuart.: "Homeostasis and differentiation in random genetic control networks.", Nature 224 (1969).
- [7] ビデオリサーチ: 関東地区視聴率調査, (2016).
- [8] Blei, David M., Andrew Y. Ng, and Michael I. Jordan.: "Latent dirichlet allocation.", Journal of machine Learning research 3.Jan (2003).
- [9] Muggleton, Stephen.: "Inductive logic programming.", New generation computing 8.4 (1991).
- [10] Marek, Victor W., and Miroslaw Truszczyński.: "Stable models and an alternative logic programming paradigm.", The Logic Programming Paradigm. Springer Berlin Heidelberg(1999).