

修士論文

適応型屋外広告配信のための 興味センシング

Interest Sensing for Adaptive Out-of-Home Advertising

2014年2月6日

指導教員 瀬崎 薫 教授

東京大学大学院 情報理工学系研究科 電子情報学専攻

48-126416 木田 裕一朗

目次

第1章	序論	1
1.1	広告を取り巻く背景と現状	1
1.1.1	屋外広告の現状	1
1.1.2	購買理論	3
1.1.3	デジタルサイネージに求められる課題	4
1.2	目的と手法の概要	6
1.3	本論文の構成	6
第2章	関連研究	8
2.1	人の興味情報を用いた広告配信	8
2.2	センサとしてのスマートフォンの利用	11
2.3	TV 広告の分類と推定	14
第3章	リーセンシープランニングについて	18
3.1	メディアプランニングにおけるリーセンシー	18
3.2	近接性と受容性	19
3.3	カテゴリーとしてのブランドの認知	20
第4章	スマートフォンを用いた興味センシングシステムの提案	21
4.1	提案システム全体像	21
4.2	技術上の課題	22
第5章	受容性に関する興味センシング手法	24
5.1	受容性に関する興味センシングのフロー	24
5.1.1	加速度の初期設定	25
5.1.2	店舗間移動時と店内閲覧時の状態判別	26
5.1.3	Bluetooth による探索	28
5.1.4	受容性に関する興味ヒストグラムの生成	29
5.2	Bluetooth による端末検知可能性	29
5.2.1	実験方法	30

5.2.2	実験結果	30
5.2.3	bluetooth の受容性に関するセンシング可用性に関する考察	31
5.3	行動認識による省電力化の可能性	33
5.3.1	実験方法	33
5.3.2	実験結果	36
5.3.3	状態判別精度及び電力消費に関する考察	38
5.4	受容性に関する興味センシングのまとめ	38
第 6 章 近接性に関する興味センシング手法		39
6.1	近接性に関する興味センシングのフロー	39
6.1.1	TV コンテンツの特徴量抽出	40
6.1.2	演算の並列化	41
6.1.3	特徴量のノイズ除去	42
6.1.4	マッチングによる TV コンテンツ推定	42
6.1.5	近接性に関する興味ヒストグラムの生成	44
6.2	評価実験概要	45
6.3	距離による精度変化	48
6.3.1	実験方法	48
6.3.2	実験結果	48
6.3.3	センシングの距離耐性に関する考察	49
6.4	解析フレーム数による精度変化	50
6.4.1	実験方法	50
6.4.2	実験結果	51
6.4.3	マッチングにおける解析フレーム数に関する考察	51
6.5	コンテンツの違いによる精度変化	52
6.5.1	実験方法	52
6.5.2	実験結果	52
6.5.3	コンテンツによる精度変化に関する考察	53
6.6	近接性に関する興味センシングのまとめ	54

第7章 適応型屋外広告配信に向けた考察	55
第8章 結論	56
謝辞	58
発表文献	
参考文献	

目次

1.1	品川駅構内のデジタルサイネージ	1
1.2	amazon における商品のレコメンド	2
1.3	Yahoo! JAPAN におけるターゲティング広告	2
1.4	AIDA 理論	3
1.5	AIDMA 理論と AISAS 理論	4
1.6	Stand Alone 型のデジタルサイネージ	5
1.7	Network 型のデジタルサイネージ	5
2.1	PRoB Router を用いたコンテンツ配信システム [20]	8
2.2	Person Wide Web システムの概要 [21]	9
2.3	PWW クライアントにおける UI [22]	10
2.4	SDP をベースにしたモバイルデジタルサイネージシステム[23]	11
2.5	被験者ごとのユーザとスマートフォンの距離の時間的割合[23]	12
2.6	平日生活行動とテレビ接触の時間帯ごとの人数[26]	14
2.7	TV と屋外広告を組み合わせることによるブランド絆度の変化[27]	15
2.8	キーワードの利用による TV 広告分類システムアーキテクチャ[28]	15
2.9	TVCM と画像データベースを用いたレコメンドシステム[29]	17
2.10	テキストベースの再検索を取り入れることによる適合率の精度向上[29]	17
3.1	リーセンサー効果	18
3.2	リーセンサーブランニング	19
4.1	スマートフォンを用いた興味センシング手法の概要	21
5.1	受容性に関する興味センシングの概要	24
5.2	店舗間移動時と店内閲覧時の加速度センサの変動の違い	26
5.3	Bluetooth による店舗探索の流れ	28
5.4	Bluetooth による端末検知可能性の実験概要	30
5.5	Bluetooth による距離と端末検出率に関する実験結果	31
5.6	経済産業省による目的地別滞在時間の調査結果	32

5.7	三軸加速度センサの値と加速度ノルムの時間変化の様子	34
5.8	被験者の歩行シナリオ	34
5.9	サンプリングレートの違いによる加速度ノルムの分散の変化	35
5.10	サンプリングレートの違いによる歩行リズムの分散の変化	35
5.11	被験者ごとの加速度ノルムの分散の変化	36
5.12	被験者ごとの歩行リズムの分散の変化	37
6.1	近接性に関する興味センシングの概要	39
6.2	二値化特徴量生成の概要	40
6.3	特徴量生成におけるスレッドを用いた並列処理の概要	41
6.4	各周波数における信号強度	42
6.5	TV コンテンツ推定における特徴量マッチング	43
6.6	年齢別 TV 視聴時間（週平均）の違い[39]	46
6.7	実験に用いた番組プログラム	47
6.8	実験に用いた部屋	47
6.9	特徴量生成時のサンプリングレート毎の距離によるマッチング精度変化	48
6.10	解析フレーム数による精度変化	51
6.11	チャンネルごとの精度変化	53
6.12	TV 番組を解析した場合と TVCM のみを解析した場合の精度変化	54

表目次

2.1	時間帯ごとのユーザとスマートフォンの距離の時間的割合[23]	13
2.2	場所ごとのユーザとスマートフォンの距離の時間的割合[23]	13
2.3	キーワードの利用による TV 広告分類の実験結果[28]	16
5.1	Bluetooth による距離と端末検出率に関する実験結果	31
6.1	イタリアにおける視聴率の高い7チャンネルの視聴比率[40]	46

第1章 序論

1.1 広告を取り巻く背景と現状

1.1.1 屋外広告の現状

我々が日々生活していく中で、広告を目にしない日はない。TV、新聞、雑誌、ラジオ、といった4大マスメディアを始めとして、近年ではデジタル技術の発展に伴い、webやデジタルサイネージ等、広告媒体は多岐に渡り、日々我々に大きな影響を与えている。実際、街を歩いていけば看板を目にするし、TVを点ければTVコマーシャルが流れ、デジタル技術が発達した今では、パソコンや携帯端末でネットブラウジングをする際にも様々な広告を目にする。このように、広告は世の中にあふれ、我々生活者に日々影響を与え、購買行動を誘発している [1] [2] [3].

その中でも、近年は無線ネットワーク技術の発達に伴い、このような広告配信を始めとした、効果的な情報配信システムの実現に向け、数多くの研究がなされている [4]. たとえば、デジタルサイネージの設置の進展 [5], 近年開発されたプロジェクションマッピングの利用 [6]や Kinect 等の技術の組み合わせにより、渋谷駅スクランブル交差点や品川駅構内など、駅・ショッピングモール内を始めとした OOH (= Out Of Home-media) と呼ばれる屋外広告 (図 1.1) は大きな注目を集めている。屋外広告には、街やロードサイドなどの屋外で展開されるメディアの全てが含まれ、代表的なものとして、街頭のネオン広告塔や大型懸垂幕、イベントスペースや大型ビジョンなどが挙げられる。これらのメディアは、街に集まる消費意欲に溢れた多くの生活者に対し、売り場に近い場所でダイレクトかつ継続的に情報を発信して、行動を喚起する機能を持っている。

しかし、このような屋外広告の情報配信に関する研究が進む一方で、情報を受け取る生活者



図 1.1 : 品川駅構内のデジタルサイネージ

の好みは人それぞれ違うにも拘らず [7], 依然配信されるコンテンツは不特定の生活者に対して一面的かつ一方的に配信されているため, 多くの場合そもそもコンテンツが見られていないという問題点が指摘されている [8]. そのため, 広告配信を考える上で, どのような生活者に対して, どのようなコンテンツを提示するか, 等のセグメントを行う必要性が生まれてきている.

例えば, アメリカ合衆国の通販サイト amazon では 図 1.2 に示すように, ユーザの購買履歴に合わせて, ユーザの興味に近いと思われる商品のレコメンドを行っている. その他にも, facebook や twitter などの SNS, Yahoo!JAPAN などの検索サイトでも図 1.3 に示すようなユーザのセグメントやキーワードによるターゲティングを行い, 広告の効果を最大限に引き上げることを目指している.

このようにオンラインでの広告配信において, このような生活者のセグメントが進む傍ら, 近年では, 様々なセンサが搭載されたスマートフォンの浸透や NFC (= Near Field Communication), その他さまざまなセンシング技術の発達に伴い, WEB 上の情報のみならず, オフラインにおける人の行動のセンシングにも注目が集まってきている [9].



図 1.2 : amazon における商品のレコメンド



図 1.3 : Yahoo! JAPAN におけるターゲティング広告

1.1.2 購買理論

一般に、生活者の購買プロセスについて考えていく上で重要な理論に、図 1.4 に示す AIDA 理論 [10] というものがある。AIDA 理論とは、1920 年代に応用心理学の分野で米国の E・K・ストロングが論文中に示した、セールスにおける顧客心理のフェーズを表したものであり、

- 1.Attention (=注意)
- 2.Interest (=興味)
- 3.Desire (=欲望)
- 4.Action (=行動)

という、生活者の購買プロセスフローを 4 つに分けてモデル化し、それぞれの頭文字をとって名前をつけたものである。さらに、この AIDA 理論を基に、アメリカ合衆国の販売・広告の実務書の著作者であったサミュエル・ローランド・ホールが著作中で示した、広告宣伝に対する消費者の心理のプロセスをモデル化した AIDMA 理論 [11] や、日本の広告代理店の電通が登録商標をもつ、ネット社会が反映した現在の購買プロセスをモデル化した AISAS 理論 [12] など、も提唱されている(図 1.5)。この 2 つの理論の間には 84 年という年月の経過が見られるものの、どちらの理論においても、生活者の Attention(=注意)と Interest(=興味)のプロセスが大事であるという点に変化は見られず、どの時代においてもこの 2 つのプロセスは重要視されているということが出来る。



図 1.4 : AIDA 理論

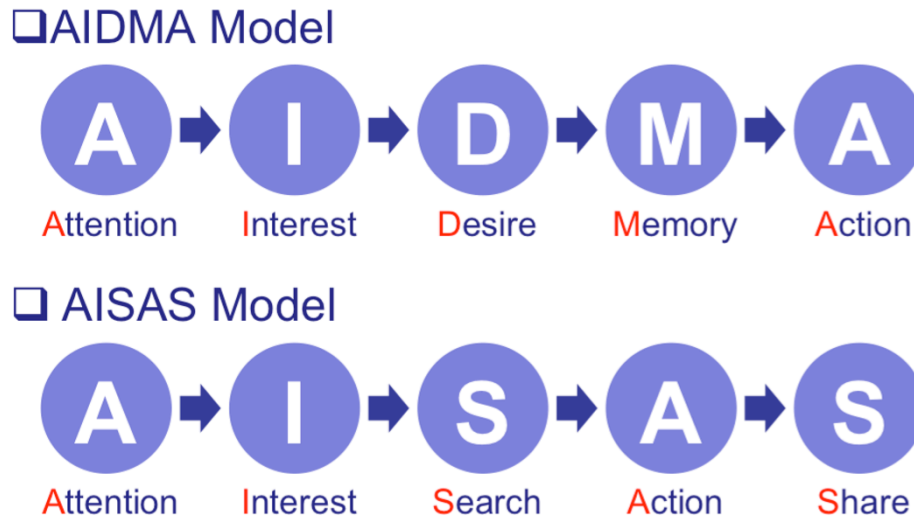


図 1.5 : AIDMA 理論と AISAS 理論

1.1.3 デジタルサイネージに求められる課題

デジタルサイネージとは、屋外や店頭などに設置される、表示や通信に際し、デジタル技術を活用し、液晶ディスプレイやプロジェクタなどによって映像や情報を表示する広告媒体である。付近にいる人や通行人に対し、広告や案内情報を表示することを目的としたもので、看板やポスターを電子化したものといえる。

現在のデジタルサイネージの広告配信方法には大きく分けて 2 種類ある。一つは図 1.6 に示すスタンドアロン型、他方は図 1.7 に示すネットワーク型である。現在設置されている物のうち、多くは前者のスタンドアロン型であるが、自由度の高さや、複数ディスプレイの連携が可能なことから、後者のネットワーク型ディスプレイに関する研究開発及び設置が進んでいる [13]。

配信する情報としては、内容 TVCM 等と同じく、映像コンテンツを配信することが多いが、そのような既存媒体と異なる大きな強みは、場所や時間、周辺環境によって変化する生活者の様々なモチベーションに合わせて、適切な広告・コンテンツを配信できる点にある。そこで、近年、デジタルサイネージで広告配信を行う際にも、生活者の注意や興味をひき、効果的な広告配信を行うために、単なる一方通行の配信ではなく個々の生活者に合わせてパーソナライズされた配信を行う必要が生まれてきた [14]。実際に、このような生活者に合わせた適応型屋外広告の配信を実現するために、数々の研究が行われてはいるものの、依然として課題は多い。デジタルサイネージなどの屋外広告は、ネット広告と異なり、個人のみではなく、複数の歩行

者から同時に見られる広告媒体であるという特性がある。そのため、単に個人ユーザの興味情報だけにフォーカスして情報を提示してしまうと、そのユーザのプライバシーを無視した情報の配信になってしまう。また、屋外広告に限らず、人の興味情報の取得に関してはネット広告を始めとして、サイト閲覧履歴などのオンライン情報を元にしたセグメントがほとんどであり、人の興味情報の現れるリソースが限定されているという課題もあげられる。さらに、人の興味情報をより広く集めようとするアプローチにおいても、ユーザ自身に直接端末上で興味情報の入力を求めるものが多く、ユーザビリティの観点からも実用には程遠いものになってしまっているケースがほとんどである。

このように、プライバシーの問題や、オンラインの興味情報への偏り、人による能動的なインプットの必要性など、依然として課題は多く、本研究で提案するような、オフラインにおける人の行動にフォーカスして興味情報を自動収集する手法に関する研究はほとんど行われていない。



図 1.6 : Stand Alone 型のデジタルサイネージ



図 1.7 : Network 型のデジタルサイネージ

1.2 目的と手法の概要

本研究は、前節で述べられたような、デジタルサイネージ付近にいるグループにフォーカスした適応型屋外広告の配信に向け、人の興味情報の収集において、オフラインの行動のセンシングを自動で行う手法の提案を目的としている。

上記目的を実現するにあたり、本稿では、このような屋外広告配信システムに関して、リーセンシープランニング [15] の考え方に基づく、適応型屋外広告配信のための興味センシング手法を提案する。リーセンシープランニングとは、Ephron によって提唱されている、人の購買行動モデルを元に、広告配信をどのように行うべきか、という考え方の一つである。リーセンシープランニングでは、人の購買行動において、回数よりも「いつ」広告メッセージを届けるかが重要であるという考えに基づいており、購買行動における生活者の心理的な購買への近さを表した「受容性」と、空間的な購買への近さを表した「近接性」という2つのポイントが重要であるということが述べられている。

この考え方をベースに、本研究では心理的な近さである「受容性」の実現においては、購買意欲と興味の相関から店舗の来店履歴を用いた。また、空間的な近さである「近接性」の実現においては、脳科学 [16] [17] [18] と統計学 [19] の側面から TVCM の視聴履歴を用いた。

また、これらの情報の自動収集の実装においては、スマートフォン(android 携帯端末)に搭載されている各種センサ、特に加速度センサとマイクを用いることにより、能動的なインプットを行うことなく、人の興味情報のヒストグラム化を行った。

技術的な側面として、受容性の実現においては、屋外でスマートフォンを利用することによる情報収集が必要になるため、興味情報収集における電力の省電力化を行った。省電力化に際しては、人の歩行時に生じる加速度の大きさ(=ノルム)に着目し、店舗間移動時と店舗内閲覧時の2つの状態を推定することによって、Bluetooth の起動時間の短縮を行った。また、近接性の実現においては、プライベート空間でのスマートフォン利用を想定し、スマートフォン上で低演算かつ高精度な TV 視聴履歴の分類の実現を行った。高精度なマッチングに際しては、視聴番組の音声を FFT(=Fast Fourier Transform)したのち、二値化特徴量を抽出し、番組表データベースとマッチングすることによって、低演算かつ高精度なマッチングを実現した。

最後に、このようにして得られた興味ヒストグラムデータを元に、屋外広告の前にいる生活者の興味情報を収集し、適応型屋外広告の配信に活かす手法を提案する。

1.3 本論文の構成

本稿の構成は以下の通りである。第2章では関連研究、第3章では本研究のベースとなるリー

センサープランニングについて述べる。そして、第4章で本提案手法の概要を示した後、第5章ではリーセンサープランニングにおける受容性に関する興味センシング手法を、第6章ではリーセンサープランニングにおける近接性に関する興味センシング手法を提案し、評価実験の結果を通して、本提案手法の有用性を示す。第7章では、第5章・第6章をふまえた適応型屋外広告配信について考察を行う。最後に、第8章で結論を示し、本稿全体をまとめる。

第 2 章 関連研究

2.1 人の興味情報を用いた広告配信

オンライン上には現れない人の興味情報を用いた広告配信については様々な研究がなされている。

その中でも、最もシンプルなものとして、Wan らは独自に開発した Profile Based Router (PRoB Router) というハードウェアを用いてユーザ情報を管理し、ユーザの選んだ情報のみを受信してコンテンツを配信するもの [20] を提案している。PRoB Router とは、図 2.1 に示すようなエンドユーザに近い、ネットワークの末端に位置するネットワークデバイスである。このシステムでは、コンテンツプロバイダもユーザもともに PRoB Router へのアクセスが可能であり、複数の配信プロトコルを用いることで、両者ともにデータのやり取りの選択をすることが可能となっており、ユーザは自分の好みに合ったコンテンツのみを受信することが出来る。コンテンツの配信にあたってコンテンツプロバイダは、プロバイダ ID、コンテンツの種類などを PRoB Router 内のローカルキャッシュに保存する。その後、受信に際してユーザは、どんな種類のコンテンツを受信したいかを事前に登録しておくことで、ユーザの好みに合わせたコンテンツの受信を可能にしている。しかし、PRoB Router のような特殊なデバイスを大規模に街中に設置することは難しく、現実的であるとは言いがたい。

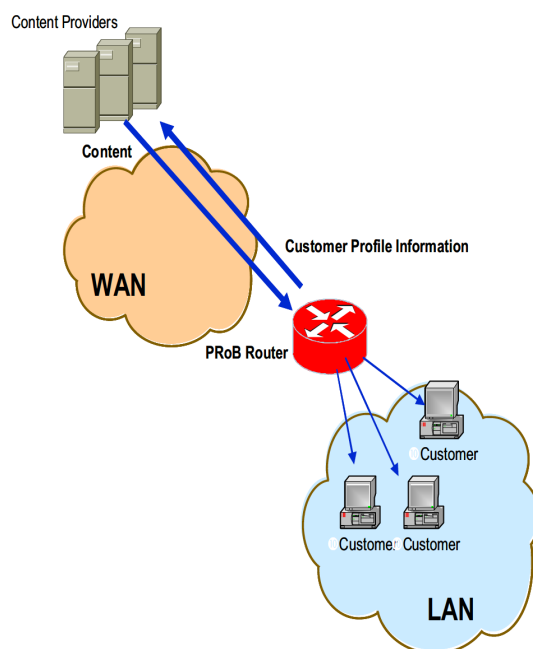


図 2.1: PRoB Router を用いたコンテンツ配信システム [20]

一方で、上記のような個人のプロフィール情報に加え、コンテンツを受信する「場所」という概念を加え、Shin らは、固定電話番号情報を元に現在地情報を取得し、さらにユーザの好みを合わせてデータを送ってもらうことでユーザのニーズに合わせた広告を配信する、図 2.2 に示すような Person Wide Web (PWW) [21] というアイデアを紹介している。PWW とは、WWW のサブセットと言える新しいタイプの web サービスアーキテクチャであり、ユーザの現在地に基づいてその場所に関係のある web 上のリソースをユーザに配信するものである。この PWW の概念の中には 3 つのサブプロトコルが存在している。一つ目は、様々なデータサービスに向け、モバイルユーザに web ドキュメントを配信する HTTP の延長と言える PTPP (PWW Text Transfer Protocol)、二つ目は、地理的に有用性のある web リソースを PUSH メッセージとして送信する PUSH Sub-Protocol、三つ目は、PUSH サーバとユーザのデバイス間のやりとりをとりもつ Management Sub-Protocol である。現状の URL は、ドメイン名や IP アドレスを元に行っているため、地理情報を元にしたコンテンツの配信には不向きであると言える。そこで、固定電話番号を元にした LID (Location Identifier) を URL 組み合わせた新たな URL を元にコンテンツ配信を行うのが、この PWW における PTPP 通信の根幹である。ユーザはこの PWW を用いることで、図 2.3 に示すように、その地域に合わせた PUSH メッセージを受け取ることが出来る、そのリストの中から欲しい情報を選ぶことで、ユーザの求めた情報のみの受信が出来るシステムとなっている。その地域に応じたコンテンツ配信という点では、デジタルサイネージなどの特性を生かしているという観点からも注目すべき点ではあるが、このシステムにおいても、現状のインフラ設備を大幅に変える必要があるという観点から、まだ現実的な手法であるとは言いがたい。

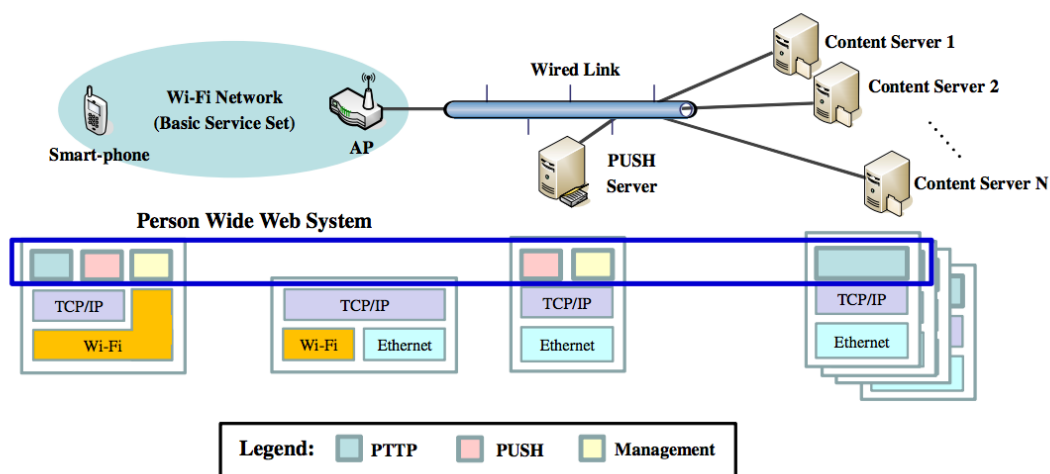


図 2.2 : Person Wide Web システムの概要[21]

そういった問題を解消し、Yoon らはオープン API を特徴とする SDP (Service Delivery Platform)をベースに、ユーザ端末の AP (Access Point)に着目し、ユーザプロフィールを元にターゲット広告を配信するモバイルデジタルサイネージシステム [22] を提案している。そのシステムの概要は図 2.4 に示す通りである。まず、広告主はサービスプロバイダにサービス依頼のリクエストを送信する。その後、サービスプロバイダは広告コンテンツの要求をコンテンツプロバイダに送信し、コンテンツサーバ内及び、サービス・ネットワークマネージャサーバ内に広告コンテンツを保存する。そして、広告主により、必要がある場合はバナーテキストなどの文面を、コンテンツマネージャを介して変更した後、店舗の POA (Point of Access)に近づいて来たエンドユーザに対して PUSH メッセージを送信する。ユーザは PUSH メッセージをリストとして確認することが出来、その中から自身の好みに合うものに合わせて選択することで、メッセージを受信することが出来る。これは別の店舗に行った場合も同様であり、さらに帰宅後、IPTV を通じて外出時に関覧した広告を見ることも可能である。この研究においては、3rd パーティによるオープンな開発環境を可能にした点や、屋外のみならず、自宅における広告配信も考慮している点が特徴的であるが、依然として前述の二者と同様に、人の興味に関する能動的なインプットが必要という課題が見受けられる。

このように、人の興味に合わせた広告配信の研究は多く行われているが、どの研究においても、人の興味に関する情報に関しては既知としている研究がほとんどであり、それらの情報を自動収集して定量化しようというアプローチは見受けられない。さらに、広告配信という観点



図 2.3 : PWW クライアントにおける UI[21]

でも、情報配信対象を個人に限定しているものが多く、屋外広告配信という観点で、デジタルサイネージ上での配信で問題となる、個人のプライバシーの問題の根本的な解決になるような研究は少ない。以上をまとめると、「オンライン上に現れない人の興味の収集手法の確立」及び「人の興味をベースにした個人のプライバシーに配慮した屋外広告配信手法の確立」が問題になっているといえる。

2.2 センサとしてのスマートフォンの利用

ユーザの行動認識を始めとして、我々人間に関する情報の収集ツールとして、様々なセンサを用いた研究が行われている。その中でも、設置コストがかからず、多くのセンサと通信機能を兼ね備え、世界中に多く普及しているスマートフォンは、実世界の情報収集ツールとして注目されており、ユビキタスコンピューティングの分野では、ユーザがスマートフォンを常に所持しているという前提のもと様々な研究に用いられている。

A. K. Deyらは、このユーザがスマートフォンを常に所持しているという点に関して、実際にユーザとスマートフォンの物理的な距離がどのくらいあるのかを計測することで、スマートフォンの近接性に関する評価実験 [23] を行っている。評価実験に際しては、関連研究として2006年に Patel らが行った、フィーチャーフォンとユーザの近接性に関する実験方法 [24] を踏襲して行っている。近接性に関しては、

- (i) 手の届く範囲 : 1 - 2m

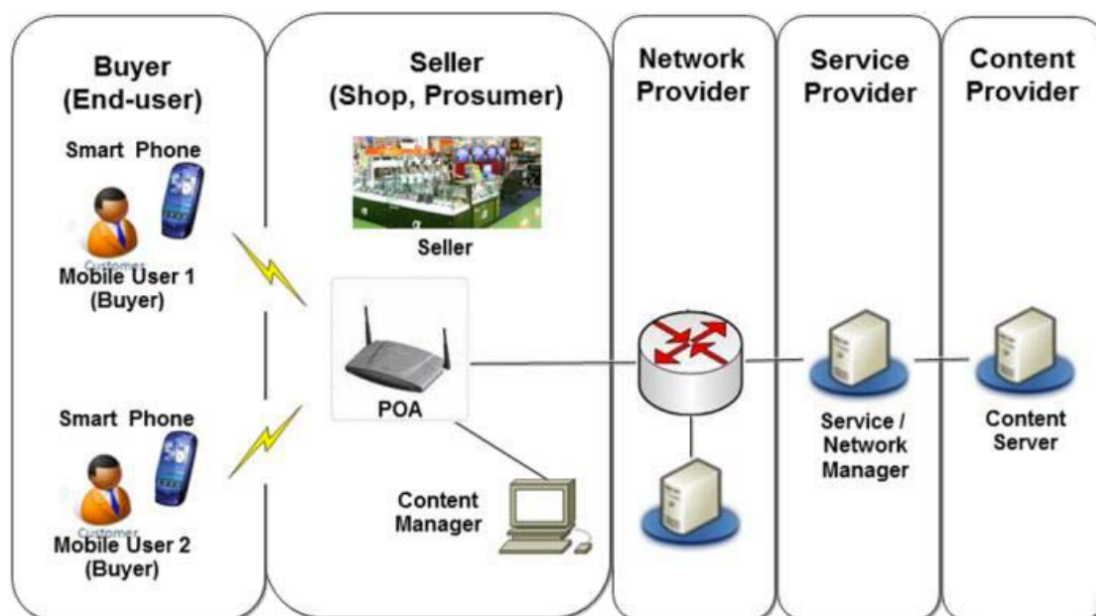


図 2.4 : SDP をベースにしたモバイルデジタルサイネージシステム [22]

- (ii) 同一室内 : 5 - 6m
- (iii) 測定不能(な程遠い) : 6m 以上

の三つに分類した上で、Bluetooth の RSSI 強度によって 1 分に一度距離を測定する実験を約 4 週間に渡って行った。また、誤測定を防ぐため、一日をエピソードごとに分けてもらい、行動・場所と時間・スマートフォンの位置について被験者に記入してもらったものを一週間に一度のインタビューを通じてデータと比較することを行った。被験者ごとにスマートフォンとユーザの距離を、時間ごとの比率で、手の届く範囲、同一室内、測定不能、電源 OFF の 4 つに分類したものを図 2.5 上部、電源 OFF を除いた場合を図 2.5 下部に示す。手の届く範囲にある場合の確率は 53%、同一室内にある確率は 88% という結果になっている。さらに、時間帯ごとのスマートフォンとユーザの距離を表 2.1 に、場所ごとのスマートフォンとユーザの距離を表 2.2 に示す。図 2.5、表 2.1、表 2.2 に示す上記結果により、時間・場所によらず、ユーザとスマートフォンは約 90% という高確率で同じ場所に存在するということが出来、ユーザの場所的なコンテキスト、情報配信、情報アクセスの近接センサとしてスマートフォンは有用であると結論づけることが出来る。

このように、ユーザの様々な情報収集及び配信に有用なスマートフォンだが、搭載されているセンサを活用して様々な情報を取得する際には注意が必要であると言える。Chronis らは、人間関係のモデリングに向け、スマートフォンを用いたプラットフォーム [25] を提案している。

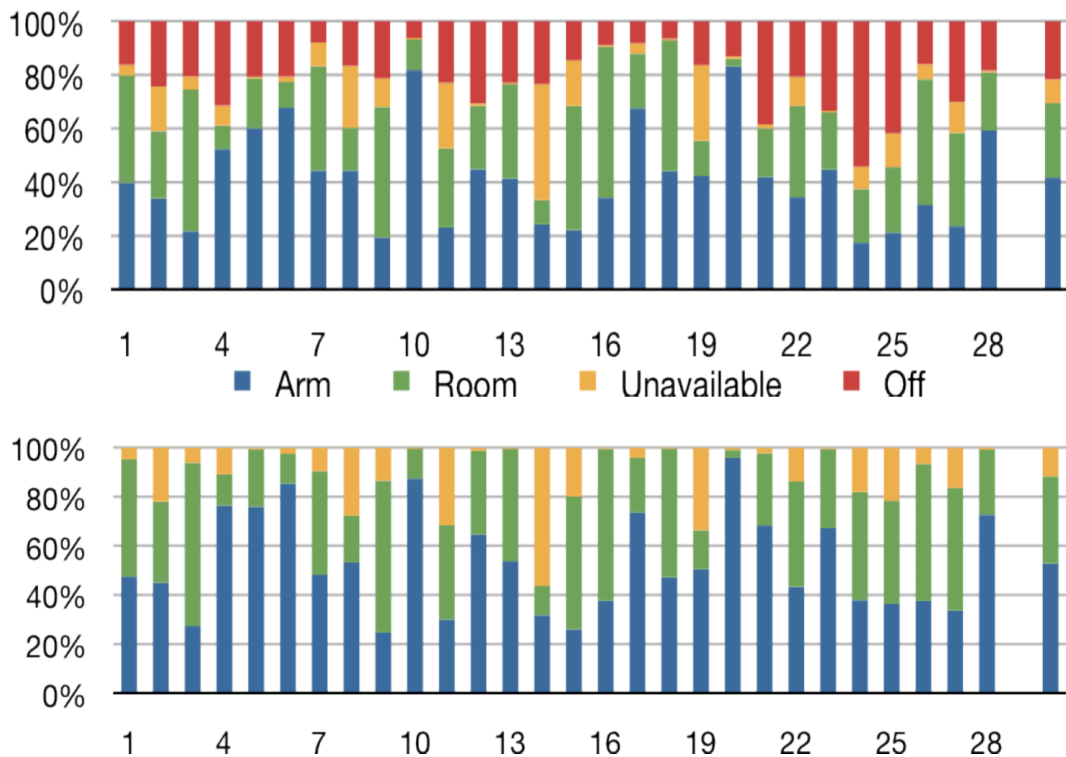


図 2.5 : 被験者ごとのユーザとスマートフォンの距離の時間的割合[23]

Chronis らのプラットフォームでは、人物同士との近接性を測定するために Bluetooth を、訪問場所取得のために wi-fi、さらに、通話履歴や SMS、視聴音楽などを利用して、人間関係の推定を行っている。その際、システム的设计に関する考察において、ユーザフレンドリーな設計として、省電力、デバイスの物理的な大きさと重さ、メモリ、オペレーティングシステムのインターフェイスをあげているが、このプラットフォームは様々な人間関係にまつわるデータ収集が可能である半面、5分ごとにバックグラウンドでユーザ特定のために Bluetooth や wi-fi を使うことで、バッテリー持続時間が約 15-20%低下すると言及されている。また、数人の被験者がプライバシーの観点から、実験に参加することにためらいを感じていたことも指摘されている。従って、このようなスマートフォンをセンサとして用いたシステムを実現する際の課題点として、「消費電力の削減」と「プライバシーへの配慮」の2点が挙げられる。

	Arm	Room	Arm + Room
Morning (7-9am)	57% (46)	30% (23)	87% (69)
Daytime (9am-6pm)	51% (40)	36% (28)	87% (68)
Evening (6-11pm)	48% (37)	40% (31)	88% (68)
Night (11pm-7am)	56% (46)	33% (26)	89% (72)
Not Night (7am-11pm)	51% (40)	37% (29)	88% (69)

表 2.1 : 時間帯ごとのユーザとスマートフォンの距離の時間的割合 [23]

	Arm	Room	Unavailable	Arm + Room
Home	46%	36%	17%	83%
Not Home	54%	31%	15%	85%
Work	48%	33%	18%	82%
Shopping	62%	20%	17%	83%
Leisure	50%	37%	13%	87%
Family	56%	33%	10%	90%
Friends	51%	30%	18%	82%
Gas	74%	3%	22%	78%

表 2.2 : 場所ごとのユーザとスマートフォンの距離の時間的割合 [23]

2.3 TV 広告の分類と推定

オンライン上の人の興味・趣向収集に関する研究が進む一方、センシング技術の発達に伴い、今までは定量化することが難しかった、オフラインにおける人の興味・趣向に関する研究にも注目が集まってきている。中でも、TV は様々なメディアの中で最も人々に好まれているメディアであり、TVCM は視聴者の購買行動を喚起する点で有力 [19] なメディアであると言われていた。さらに、ユーザは TVCM を視聴したときの情報を符号化する際、注意と記憶に関係のある前頭部及び前頂葉部が能動的な役割を持ち [16] [17]、実際に過去に見て記憶している TVCM を後日目にすると、その記憶に関わる前頭部及び前頂葉部が刺激されることが明らかとなっている [18]。

さらに、このような TV と屋外広告というこの二つのメディアはとても相性がよい。図 2.6 に示すように、TV 接触後の通勤・通学時、もしくは TV 接触前の帰宅時に、交通広告や屋外広告に接触する可能性が高く、このような屋外広告と TV のシナジー効果が期待出来る [26]。実際に、大手飲料メーカーのブランド絆度に関しても、図 2.7 に示すように屋外広告や街頭ビジョンに接触した場合の方が、非接触の場合に比べて、理解・好意・選択候補・推奨の 4 つの項目全てにおいて、TV と屋外広告を組み合わせることによるブランド絆度の上昇が認められる [27]。

このように、TV という広告媒体は、人の興味・関心に大きな相関が認められるメディアの一つであり、さらに屋外広告との大きなシナジー効果が認められるという点から、アウトオブホームメディアの領域と TV の領域を組み合わせ、クロスメディアの広告配信の手法は、人の購買行動に大きな影響を与えることが出来ると期待出来る。そこで、上記のような特徴を持つ、映像コンテンツや TVCM の解析に関して、今までは TV 番組からどのように TVCM を区別し




図 2.6 : 平日生活行動とテレビ接触の時間帯ごとの人数 [26]

て除外するかにはフォーカスされていたのに対し、近年では、TVCM 自体を解析して分類する研究も多々行われてきている。

Zheng らは、TVCM の映像及び音声内のキーワードを抽出することにより、音声認識の精度を上昇させ、TVCM をカテゴリ別に分類する研究 [28] を行っている。手法としては、図 2.8 に示すように、まず、TVCM のカテゴリライズに用いるための辞書となるデータベースをマニュアルで作成した。その後、ASR (Automatic Speech Recognition)及び OCR (Optical Character Recognition)を用いることにより、映像もしくは音声内にブランド名が含まれている場合は、そのブランドの所属するカテゴリに分類する。一方、ブランド名が含まれていない場合は、OCR により、映像中で特に大きな文字で書かれているキーワード、もしくは、ASR により取得されたキーワードを元に Google で検索を行った後、辞書となるデータベースの情報を用いてカテゴリの分類を行った。その結果、表 2.3 に示すように、ASR のみでの分類では 43.3%の分類精




図 2.7 : TV と屋外広告を組み合わせることによるブランド絆度の変化[27]

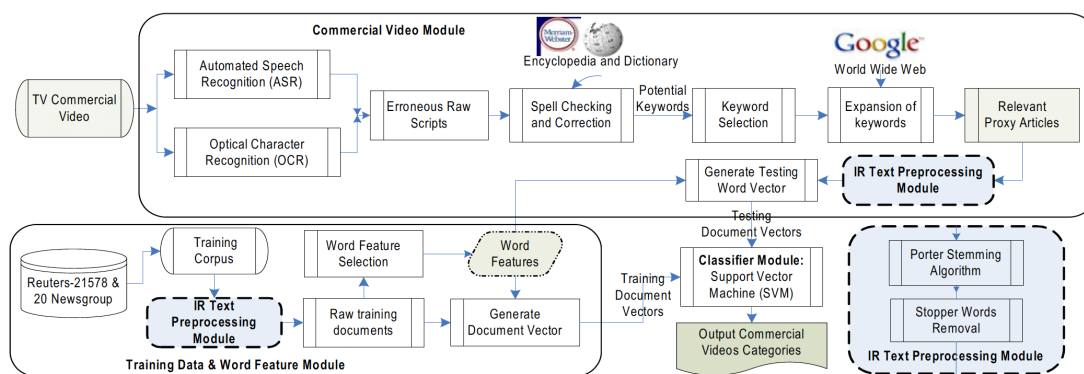


図 2.8 : キーワードの利用による TV 広告分類システムアーキテクチャ[28]

度しか出なかったのに対し、提案手法ではマニュアル分類の 85.8%に迫る、80.9%という高い分類精度の実電に成功している。考察として、Zheng らは、IT 分野に関する分類精度の低さに関して、元の辞書となるデータベースのカテゴリ定義のミスマッチが原因であると結論づけている。しかし、この手法は考察でも述べられているように、辞書となるデータベースの精度に大きく依存する上、実際の TVCM 中の画像や音声で商品情報が詳細かつ明確に述べられている場合を除き、この手法が効果的であるとは言い難い。

そこで、Wang らは、オンライン上の映像広告中に現れるプロダクトの画像を画像データベースと参照し、該当するプロダクトにまつわるキーワードを再検索することで、映像コンテンツに関係のある e-コマースサービスのレコメンドを行う研究 [29] を行っている。その一連の流れを図 2.9 に示す。レコメンドに際しては、まず、ショッピングサイトから商品画像のデータセットを集めた。その後、TVCM の中から特に特徴的なショットを抽出し、特徴点マッチングにより、先ほどの商品群データベースと参照することで、抽出された映像についてテキストタグを付与した。最後にタグ情報をもとにテキストベースの検索を再度行うことで、タグに最も近い商品に関する広告を提示し、商品のレコメンドを行っている。この結果、図 2.10 に示すように、テキストベースの再検索を取り入れることによる、適合率の精度の向上が述べられているものの、大量の画像データベースが必要である等、計算コストが高くなってしまいうことが課題であ

	Auto	Finance	Health	IT	Count	Recall (%)
(a). Classification with manually recorded speech transcripts						
Auto	38	2	0	1	41	90.2
Finance	1	28	2	2	33	84.8
Health	3	1	50	4	58	86.2
IT	0	1	3	5	9	55.6
Sum	42	37	59	8	141	
Precision(%)	94.5	89.2	96.6	75.0		85.8*
(b). Classification with ASR transcripts						
Auto	19	22	0	0	41	46.3
Finance	9	9	13	2	33	27.3
Health	2	14	31	11	58	53.5
IT	1	1	5	2	9	22.2
Sum	29	46	49	14	141	
Precision(%)	65.5	19.6	63.3	14.3		43.3*
(c). Classification with proxy articles						
Auto	35	3	2	1	41	85.4
Finance	3	25	2	3	33	75.8
Health	3	1	50	4	58	86.2
IT	0	3	2	4	9	44.4
Sum	40	35	55	11	141	
Precision(%)	90.0	80.0	90.1	36.4		80.9*

* Overall classification accuracy

表 2.3 : キーワードの利用による TV 広告分類の実験結果[28]

ることが出来る。

これらの研究では、約 80-85%という比較的高精度な TVCM の分類には成功しているものの、TVCM の分類に際しては、ユーザの視聴した映像コンテンツのオリジナルデータが必要な上、膨大な量のデータベースを用いた「高度な演算」が必要であるという前提がある。しかし、視聴された TV コンテンツの分類において、ユーザが観たままの映像データを取得することは現実的であるとは言えず、特に、データベース上のコンテンツが膨大に増えた場合には、精度が大幅に下がってしまうという問題点も挙げられる。さらに、そのようにして得られた情報を二次的に幅広い媒体において広告コンテンツ配信に利用するにはまだ課題点も多い。

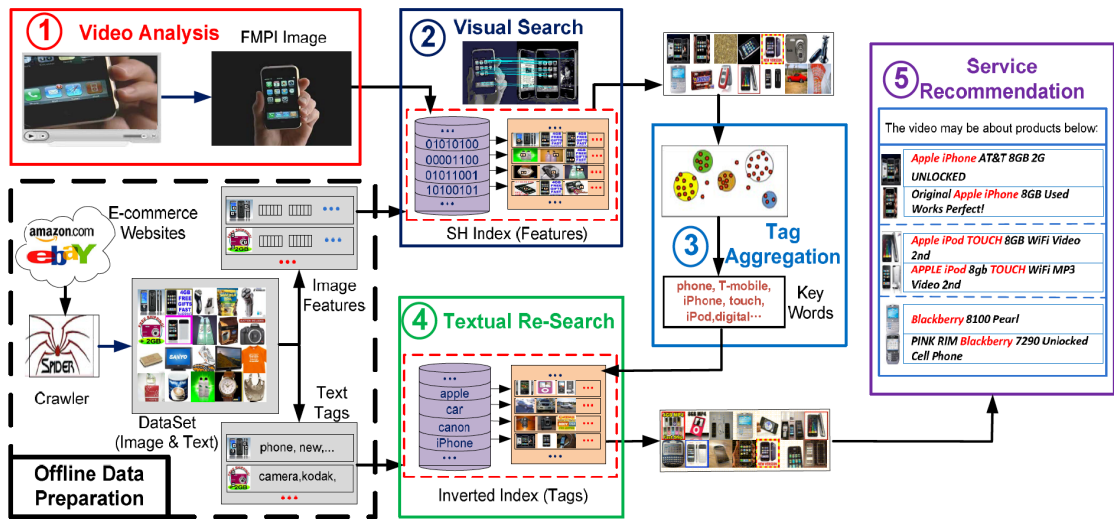


図 2.9 : TVCM と画像データベースを用いたレコメンドシステム[29]




図 2.10 : テキストベースの再検索を取り入れることによる適合率の精度向上[29]

第3章 リーセンシープランニング

3.1 メディアプランニングにおけるリーセンシー

人の購買行動における理論の一つに、メディアのリーセンシー効果というものがある。これは、「直前に接触した広告が購買行動に影響を与える」効果と定義されている [30]。例えば、図 3.1 に示すように、仕事帰りで疲弊した帰宅途中のサラリーマンが街中を歩いている状況を想定してみる。街中のデジタルサイネージ上には SUNTORY 角の広告が掲載されている。このとき、このターゲットとなるサラリーマンが、「一杯飲みに行くか」と近くの居酒屋に角ハイボールを飲みに行ったり、「帰宅したら飲もう」とスーパーマーケットで角を購入したりといった形で、購買行動に影響を与える効果がこのリーセンシー効果である。

このようなリーセンシー効果を始めとした、「リーセンシー」に関する考え方は、Ephron が発表した文献 [15] に端を発する。古い広告モデル (=Strong model)では、広告の力は強いものと考え、広告メッセージが生活者をコントロールすると考えているのに対し、Ephron らの唱える新しい広告モデル (=Weak model)[15]では、広告の力は弱く、生活者自身が広告メッセージをコントロールし、多くの広告を除く、ごく僅かな彼らに関係のあるものだけが選ばれると考えている。このような広告の力が弱い中で、最大のパフォーマンスを発揮するために考えられているキーファクターとなるのが「リーセンシー」である。Ephron は、「リーセンシーは、広



図 3.1 : リーセンシー効果

告メッセージが商品を購入しようとしている消費者に対して最も直接的に機能する」と述べている [15]. Ephron によって提唱されているこの考え方はリーセンシープランニングと呼ばれ、メディアプランニングの現場に用いられている。また、このリーセンシープランニングにおいては、ある商品を購入しようとしている生活者ではなく、購入する行為そのものにフォーカスしているため、生活者の購入頻度に関しては考慮していない。リーセンシープランニングにおける最終目標は、心理的にも場所的にも購入に近い確なタイミングでブランドメッセージを届けることであり、どのくらいの頻度で生活者がその商品を購入するかという部分に関しては、リーセンシープランニングとは別軸の問題であると述べられている。

3.2 近接性と受容性

リーセンシープランニングにおいては、「回数」よりも「いつ」広告メッセージを届けるかが重要であるという考えに基づき、図 3.2 に示すような、「受容性」と「近接性」という2つのコアアイデアが紹介されている。受容性とは購買態度など心理的に購入の準備のできた消費者に受け入れられること、近接性とは、空間・行動的に市場の中にいる消費者との近さ、を表している。しかし、このアイデアは、回数よりもメッセージを届けるタイミングが重要であるからといって、一度だけ広告メッセージを届ければ良い、というような広告費を削減するためのアイデアではない。購入意欲のない生活者に対して繰り返し広告メッセージを届けることを無意味であると考え、購入意欲の高い生活者に対してきちんと広告メッセージを届けようとするものであり、広告メッセージを届ける頻度を完全に排除するものではないという点に注意が必要

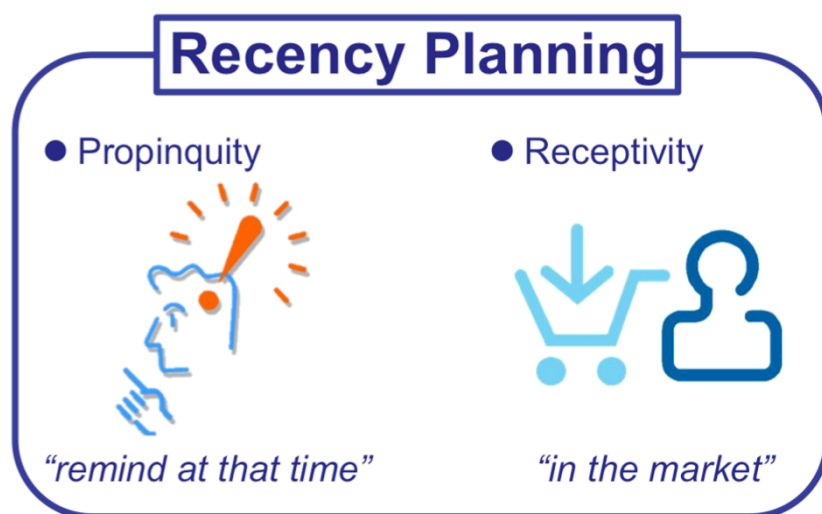


図 3.2 : リーセンシープランニング

である。このような受容性と近接性を実現するためには、数少ない購入の準備のできた生活者に対し、その場でメッセージを届け、広告を思い出させることが重要であり、この考え方は情報があふれている現代にはとても有効な手段であるといえる [15]。

3.3 カテゴリーとしてのブランドの認知

Ephron らの唱える新しい広告モデル (=Weak model) [15] では、広告のほとんどがすでに生活者の知っている製品やブランドに関するものであるため、多くの広告メッセージは生活者にとって重要なものではなく、広告によるリマインド効果はあるものの、生活者はほとんどそこから情報を得ることはなく、生活者は広告されているブランドを商品のカテゴリーで認識すると述べられている。

例えば、Zoff のパソコン用メガネの TVCM を見ても、一定時間経過後に思い出した時に、ぼんやり「メガネの CM を見た」とは覚えていても、それが Zoff というブランドのなんという名前の商品であったということは愚か、そのメガネの種類がパソコン用メガネの CM だったということですらあまり覚えてはいないといった具合である。

このように、生活者は広告された商品やブランドをカテゴリーで認識しており、たいいていの広告メッセージは除外され、その時に彼らに関係のある数少ない広告だけが選ばれ、生活者にメッセージとして届くものであると言われている。

第4章 スマートフォンを用いた興味センシングシステムの提案

4.1 提案システム全体像

本稿で提案する手法は、リーセンシープランニングの考え方をベースに、スマートフォンをセンサとして用いることで、人の興味に関する情報を収集するというものである。第2章で述べたように、屋外広告における人の興味情報の取得に際しては、「人の興味の収集手法の確立」及び「人の興味をベースにした個人のプライバシーに配慮した屋外広告配信手法の確立」という課題がある。また、スマートフォンをセンサ用いる場合にも、「消費電力の削減」と「プライバシーへの配慮」という課題がある。さらに、屋外広告と相性の良いTV広告に関しても、視聴したTVCMの分類・解析において、「高度な演算が必要」とあるという課題がある。

そこで、我々は、リーセンシープランニングの考え方をベースに、人の能動的な入力無しにスマートフォンをセンサとして用いることで、自動的に人の興味に関する情報を収集する手法を提案する。その概要を図4.1に示す。人の興味の定量化に関しては、3.3節に示すように、人は広告された商品やブランドをカテゴリで認識すると言われている [15]。そのため、本研究でもこのリーセンシープランニングの考えに即し、カテゴリ別に人の興味をヒストグ

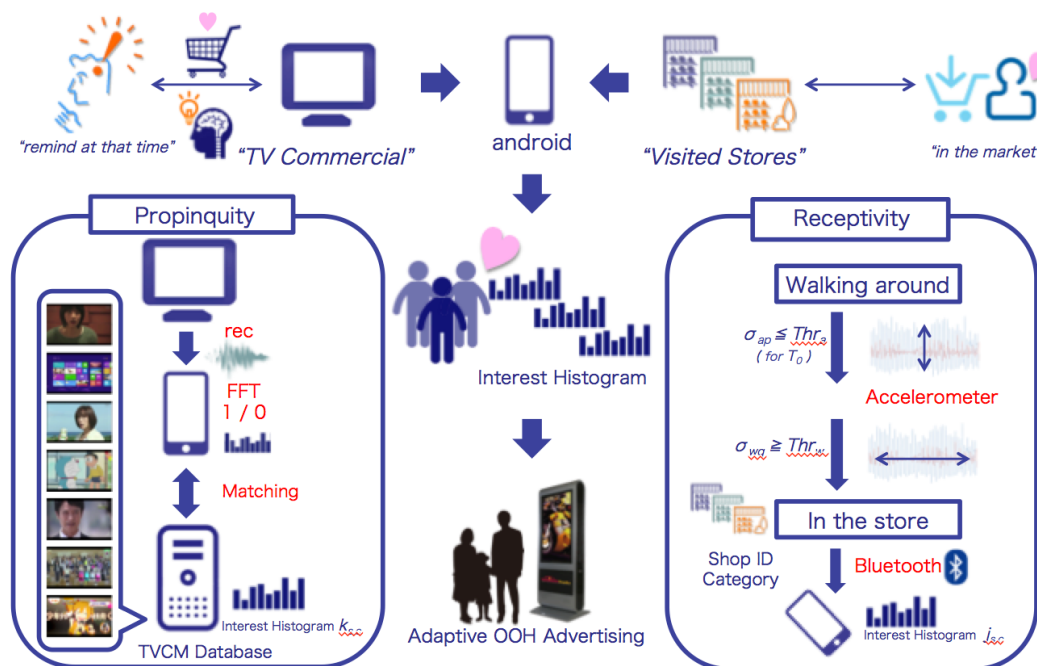


図 4.1 : スマートフォンを用いた興味センシング手法の概要

ラム化することで、屋外広告配信に際して有用な情報を生成することを考える。受容性の側面に関しては、加速度センサと Bluetooth を組み合わせることで、省電力を実現しながら店舗来店店の自動検出を行った。さらに、近接性の側面に関しては、屋外広告と TV 広告のシナジー効果の高さに着目し、我々は番組放送データと音声特徴量をベースに TVCM 視聴の自動検出を行った。最後に、これら2つの興味情報を元に、個人の興味情報を集積することで、グループの興味を生成し、個人のプライバシーに配慮したグループにフォーカスした屋外広告配信システムを提案する。本稿で提案する興味センシングによって収集された興味データを利用することにより、デジタルサイネージのリアルタイム性という特性を活かした、生活者にとって邪魔に感じることの少ない快適な広告配信による、広告効果の上昇が期待出来る。また、このような興味情報収集のプラットフォームが出来ることにより、広告配信のみならず、似た趣向を持つ人同士を結びつけたり、個人の趣向に合わせた観光ナビゲーションを行ったりといった、スマートシティの開発にも貢献することが期待出来る。

4.2 技術上の課題

前節提案した興味センシングのシステムを実装するにあたり、解決すべき技術上の課題がいくつかある。本節では、解決すべき技術上の課題について述べる。前節でも述べたように、屋外広告における人の興味情報の取得に際しては、「人の興味の収集手法の確立」が課題となっている。我々は、この課題に関して、リーセンサープランニングの考え方を切り口に、受容性と近接性という二つの側面から、スマートフォンを人の興味情報収集のセンサとして用いることで、人の興味情報の収集システムの実現を行う。以下、この受容性と近接性の側面から興味センシングを行う際の課題について論じる。

受容性の側面においては、店舗来店履歴データの取得を行うが、この際の課題として、

- ・消費電力の削減
- ・プライバシーへの配慮

以上の二つが挙げられる。受容性の実現に向けた店舗来店履歴データの取得においては、ユーザが店内に入ったことをセンシングする必要がある。それを感知するために、ユーザの位置を推定するためのセンサとして、wi-fi, GPS, Bluetooth, NFC が挙げられる。今回の位置推定においては、店内というほとんどが建物内での利用を想定しているため、測位に人工衛星を用いる関係上屋内測位に制限のある GPS は今回のセンサとして不適であるとした。さらに、NFC も、デバイスとデバイスを至近距離で接触させるというユーザの能動的な行動が必要であるという観点から不適であるとした。最後に、wi-fi だが、こちらも wi-fi のインフラが整っているという前提が必要であり、使用に制限があるという観点から不適であるとした。一方で、bluetooth は、

2台の端末さえあれば双方を検知することが可能であり、一方を店舗内に、他方をユーザが所有することで、ユーザの位置の推定が可能となる。従って、本研究における受容性実現のために最適なセンサは Bluetooth であるとした。Bluetooth は、省電力の観点では、GPS、wi-fi に比べて省電力ではあるものの、第2章で、ユーザ特定のために Bluetooth や wi-fi を使うことで、バッテリー持続時間が約 15-20%低下すると言及されている [25] ように、改善の余地があるといえる。さらに、店舗の来店などの履歴を収集する際のプライバシーに関して、ユーザ情報をやり取りすることとなると、情報漏洩の危険がある。そのため、店舗情報をユーザに送るのみにとどめ、ユーザに関するデータの送信は行わないなど、個人情報に配慮したデータのやり取りの手法が必要となる。そこで、第5章では、受容性に関する興味センシングに伴い、ユーザの歩行状態を推定することで、店舗来店履歴を取得する際の、Bluetooth の起動及び探索時間を短縮し、センシングにおける電力消費を削減する手法を提案する。

また、近接性の側面においては、屋外広告と相性の良い TV 広告を題材として、視聴した TVCM の分類を行うが、これをスマートフォン上で行う際の課題として、

- ・低演算処理
- ・プライバシーへの配慮

以上の二つが挙げられる。第2章でも示したように、TV 広告の解析や推定においては、TVCM 中のカットからデータベースを用いた画像解析を行う等、ユーザ視聴番組の情報収集において、高度な演算処理が必要であった。しかし、それをスマートフォン上で実装するには、ユーザの能動的な行動が必要である上、さらに、スマートフォンは PC と異なり、リソースが限られている観点から、これまでの解析手法とは全く異なる解決策が必要である。また、iPhone 上の iOS に搭載されている Siri などは、音声情報をサーバに送ることで高度な音声解析を行っているが、広告に応用すると技術として、今後広くユーザのプライバシーを考慮すると、Siri に代表されるような、音声データをそのままやり取りする手法は望ましいとは言えない。そこで、第6章では、近接性に関する興味センシングに伴い、番組表データを用いることで、視聴番組の解析におけるデータマッチング対象を限定し、音声データの特徴量をスマートフォン上で二値化することによって、プライバシーに配慮しながら低演算でマッチングを行う手法を提案する。

第5章 受容性に関する興味センシング

5.1 受容性に関する興味センシングのフロー

人々の購買行動と店への来店との相関は強い関係にある。来店や商品を手に取る等の購買行動中の反応や行為は、人々のその対象への興味に関する情報を含んでいる [31] ため、このような行動は購買行動に大きな影響を与えていると言える。

上記背景から、本研究ではリーセンシープランニングにおける受容性を実現するため、消費電力の削減とプライバシーへの配慮を考慮しながら、店舗の来店履歴情報を人が能動的にインプットすること無く記録する手段を考える。このような来店履歴をインプットする方法として、前節で示した、他のセンサと比較したときの Bluetooth の優位性、及び、清水らの研究[32]でも、Bluetooth の近接センサとしての有用性が明らかにされていることから、今回は Bluetooth を用いて、リーセンシープランニングにおける受容性を実現することとした。

しかし、第2章で、ユーザ特定のために Bluetooth や wi-fi を使うことで、バッテリー持続時間が約 15-20%低下すると言及されている [25] ように、Bluetooth をセンサとして用いる場合には、必要となきのみ起動する必要がある。我々は、先攻研究として、人の歩行状態と静止状態を区




図 5.1 : 受容性に関する興味センシングの概要

別する研究を行っている [33]. しかし, 来店履歴情報を取得するに際し, 店内を見ている際も, 店の前を通過している際も, ユーザが静止するのは一時的であり, そのアルゴリズムをそのまま適用することは出来ない. 一方で, 佐藤らの研究によれば [34], 歩容特徴を用いて, 群衆の中から個人を特定してトラッキングが可能になると言われている.

そこで, 本研究では「店内を見ている」状態時のみ Bluetooth を起動させるため, 人の歩行状態, 特に加速度ノルムと歩行のリズムの変化を組み合わせることによる状態推定手法を提案する. その概要を図 5.1 に示す. 人は各個人によって異なる歩容特徴を示す[34]ため, ある一定時間内の加速度の分散と歩行のリズムの周期に着目すれば, 「店の前を通行している」状態と「店内を見ている」状態とで, 大きな変化が見られると考えられる.

5.1.1 加速度の初期設定

ユーザの歩行状態の推定において, 本提案手法では加速度を用いて, 店舗移動時と店内閲覧時の二つの状態を分けることを行う. しかし, 地球の重力に起因する加速度が常に発生している関係上, 加速度センサを用いるにあたり, 常にノイズとして地球の重力にまつわる加速度が計測されてしまうという課題がある. さらに, この加速度センサの示す値は端末ごとに個体差があり, ばらつきを生じるため, 一概に重力加速度である $9.80665[\text{m/s}^2]$ を計測値から引けば, 歩行に関する加速度情報が得られるという訳ではない.

そこで, 本提案手法では, まず, 歩行にまつわる加速度情報のみを抽出するため, 加速度センサの初期化を行った. 加速度センサの初期化にあたっては, センシング開始後 10,000 ミリ秒間に計測された, スマートフォンの三軸加速度センサのノルムを配列 `gravity[]` に格納し, それらの平均値を取ることで, 重力加速度の大きさ `gravity` を算出した.

$$gravity[i] = \sqrt{a_x[i]^2 + a_y[i]^2 + a_z[i]^2}$$

(※ i は 10,000 ミリ秒の間, センサの値が更新されるたびにインクリメントする)

$$gravity = \frac{\sum gravity[i]}{i_{gravity}} \quad (\text{※}i_{gravity} \text{ は } 10,000 \text{ ミリ秒後の, } i \text{ の値})$$

このようにして得られた重力加速度の大きさ `gravity` を, ユーザの端末における重力加速度の大きさとして最初に記憶させることで, 端末間の誤差によらないロバストな歩行状態に関する加速度情報の抽出が可能となり, 高精度な状態判別の推定が可能となる.

5.1.2 店舗間移動時と店内閲覧時の状態判別

本提案手法では、受容性に関する興味情報の取得に際し、Bluetooth の起動回数及び起動時間を減らすことで、消費電力を削減することを考える。消費電力の削減に際して、本研究では、ユーザの店舗間移動時と店内閲覧時における、加速度センサから得られた加速度ノルムの変動における違いに着目した。このような加速度センサの変動の違いを図 5.2 に示す。店舗間移動時の加速度ノルムが青線で示したもの、店内閲覧時の加速度ノルムが赤線で示したものである。青い線で示された店舗間移動時は、重力加速度である $9.8[\text{m}/\text{sec}^2]$ あたりを中心として、比較的大きな振幅かつ一定のテンポで加速度を生じることが見受けられる。一方、赤線で示された店内閲覧時は加速度の振幅は大きく減少し、テンポも不規則になっていることが分かる。このように、三軸加速度センサによって得られたデータを解析することにより、店舗間移動時と店内閲覧時の二つの状態の判別が可能となり、興味情報のセンシングにおける消費電力の削減が可能になると考えられる。

具体的には、図 5.1 に示すような 2 段階の評価により状態の推定を行う。まず始めに、約 20Hz の頻度で 3 軸加速度センサから値を取得し、3 軸加速度センサから得られた x, y, z 軸の値、 a_x, a_y, a_z から、加速度ノルム $\|A\|$ を算出する。

$$\|A\| = \sqrt{a_x^2 + a_y^2 + a_z^2}$$

そして、ある一定時間のサンプリングレート T_s を設定し、ある時刻 t_p から時刻 $t_p' (= t_p + T_s)$ に




図 5.2 : 店舗間移動時と店内閲覧時の加速度センサの変動の違い

おける，時刻 i におけるサンプリングレート内の加速度ノルム $\|A_{i1}\|, \|A_{i2}\|, \dots, \|A_{in}\|, \dots, \|A_{iTs}\|$ の分散 σ_{ap} を求め， σ_{ap} が閾値 Thr_a をある一定時間 T_0 の間下回ったとき，次のステップへと進む．

$$A_{average} = \frac{\sum A_i}{i_{varp}} \quad \text{for } T_s$$

$$\sigma_{ap} = \sum \frac{(A_i - A_{average})^2}{i_{varp}} \quad \text{for } T_s$$

(※ i は T_s 秒の間，センサの値が更新されるたびにインクリメントする)

(※ i_{varp} は T_s 秒間に計測された加速度ノルムの個数)

$\sigma_{ap} \leq Thr_a$ for T_0 ... 次の評価へ

次に，歩行のリズムの周期に着目する．まず，前節で述べた android 端末を静止させた状態の加速度を *gravity* として保存しておく．そして，ある時刻 t_{q-1} における加速度ノルム $A_{t_{q-1}}$ と， t_q における加速度ノルム A_{t_q} に着目し，

$$A_{t_{q-1}} \geq gravity > A_{t_q}$$

を満たす t_q と，次にこの条件を満たす t_q' との差分から，歩行の周期 R_{wq} を算出する．

$$R_{wq} = t_q' - t_q$$

その後，ある一定時間のサンプリングレート T_s 内の時刻 j における歩行リズム $\|R_{j1}\|, \|R_{j2}\|, \dots, \|R_{jn}\|, \dots, \|R_{jTs}\|$ の分散 σ_{wq} を求める．店内を見ている時はこの歩行リズムが不規則となり，分散 σ_{wq} が大きくなるため， σ_{wq} が閾値 Thr_w を上回ったとき，「店内を見ている」状態になったとする．

$$R_{average} = \frac{\sum R_j}{j_{varp}}$$

$$\sigma_{wq} = \sum \frac{(R_j - R_{average})^2}{j_{varp}} \quad \text{for } T_s$$

(※ j は T_s 秒の間，センサの値が更新されるたびにインクリメントする)

(※ j_{varp} は T_s 秒間に計測された歩行リズムの個数)

$\sigma_{wq} \geq Thr_w$... 「店内を見ている」状態へ

5.1.3 Bluetooth による探索

「店内を見ている」状態に入った後、ユーザの持つ android 端末(=クライアント)は Bluetooth を起動し、Inquiry mode による ID の探索を行う。その流れを図 5.3 に示す。この際、店舗内にある Bluetooth 端末は、常に店舗 ID と店舗のカテゴリーを併記したデバイス名をブロードキャストしている。ユーザは、ID の探索にあたり、店舗内にある Bluetooth 端末(=サーバ)のデバイス名から、店舗 ID(=s_ID)と店舗のカテゴリーの情報(=s)を受け取る。このやりとりにおいて、ユーザは自身の ID をブロードキャストしないため、個人情報漏れといった、プライバシーの問題は起きえない。また、ユーザが Bluetooth 探索をするにあたり、店内には他にも沢山のユーザがいたり、隣接する店舗内にも Bluetooth 端末があったりといった状況を踏まえると、Bluetooth の端末検知可能範囲である 10m 以内に複数のデバイスが含まれる可能性が高い。そこで、本提案手法では、最寄りの店舗の情報のみをユーザの端末に送るため、デバイス名を“SHOP_店舗 ID_カテゴリー”といった形に限定し、その型に合っているもののうち、最も Bluetooth の RSSI 値の高いものを閲覧中の店舗のブロードキャストしている ID であると認識させるようにした。

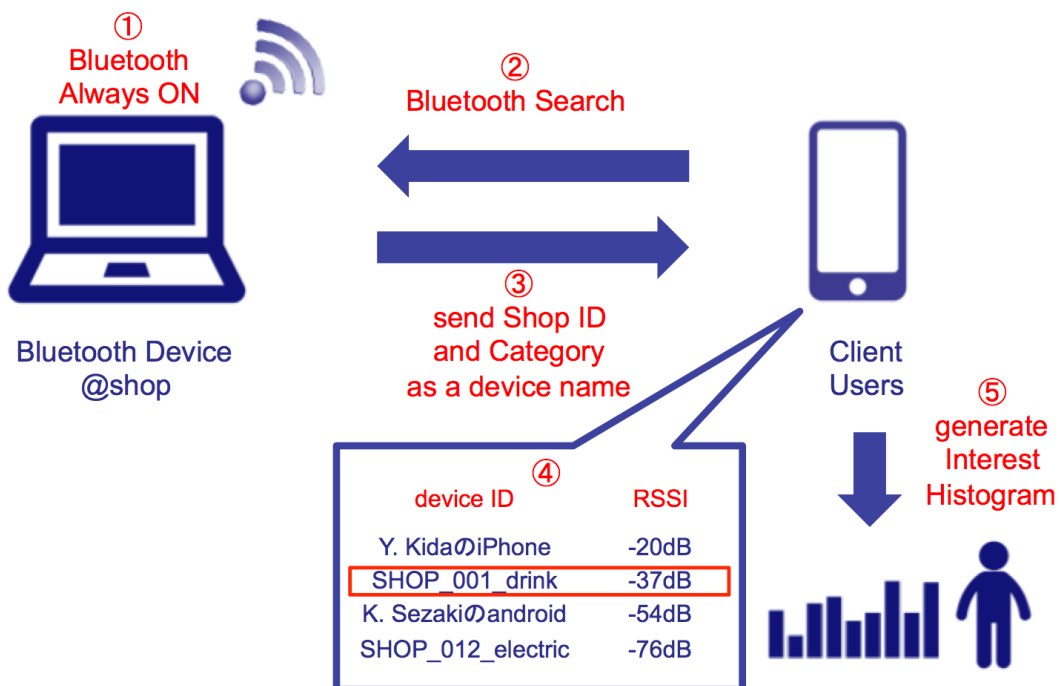


図 5.3 : Bluetooth による店舗探索の流れ

このようにして得られた店舗 ID と店舗カテゴリーから、次節に示すようにして、ユーザの受容性に関する興味ヒストグラムを生成する。

5.1.4 受容性に関する興味ヒストグラムの生成

Bluetooth 探索によって得られた店舗 ID 及び店舗カテゴリーの情報を元に、そのユーザ c の受容性に関する興味ヒストグラム $j_{s,c}$ を生成する。生成にあたっては、店内にいた時間の長さ分を、ユーザ c のカテゴリー s に関する興味ヒストグラム $j_{s,c}$ に加算することで実現する。店内閲覧の時間の算出においては、Bluetooth 探索開始時間を店内閲覧開始時刻 T_{start} とし、その後、 σ_{ap} が閾値 Thr_a を超えたとき「店の前を通行している」の状態に戻った、つまり、店内の閲覧が終了した時刻 T_{finish} とした。この時刻 T_{finish} と T_{start} との差分を取ることで、店内に滞在し、閲覧した時刻 T_{stay} を求めた。最後に、この店内閲覧時間 T_{stay} をもとに興味ヒストグラムを更新した後、Bluetooth を終了する。

$$T_{stay} = T_{finish} - T_{start} \quad (*T_{stay}: \text{店舗にいた時間の長さ})$$

$$j_{s,c} += T_{stay} \quad (*s: \text{ショップのカテゴリー})$$

$$\sigma_{ap} > Thr_a \quad \text{for } T_0 \quad \dots \quad \text{「店の前を通行」へ戻る}$$

5.2 Bluetooth による端末検知可能性

Bluetooth には、電波強度を規定した Class という定義がある。各 Class の違いは以下の通りである。

Class1	100mW	100m
Class2	2.5mW	10m
Class3	1mW	1m

一般に、スマートフォンに搭載されている Bluetooth の規格は Class2 が一般的である。そもそも、端末検知における電力削減のための方法として、この Class を変更することも可能ではあるが、そのためにはユーザにアダプタを付けてもらう必要性や、通信可能範囲が 1m となってしまった場合、本研究のような、店舗来店履歴から人の興味情報をセンシングする目的に対し、通信可能距離が極端に短くなってしまいう課題点が挙げられる。そのため、本提案手法では Class の変更は行わず、Bluetooth 自体の起動回数を減らすことを目的とした。一方で、Class2

をこのようなユーザの受容性に関する興味センシングに利用するにあたり、Class2 の通信可能範囲は約 10m であると言われているが、通信可能であることと、安定した端末の検知が可能であることは異なる。

そこで、本節では本研究に先立ち、店舗内における Bluetooth の端末検知における通信可能範囲の限界と、本研究における Bluetooth の有用性を評価するための予備実験を行った。

5.2.1 実験方法

本実験では、2 つの Bluetooth 端末間の距離を変化させることによる、RSSI 値の変化と検出確率の変化を確かめた。実験に際しては、周囲に遮る物の無いコンクリートの広い敷地内において、Bluetooth 検出を許可した mac book pro を、周囲にある Bluetooth 端末を探索出来るように実装した android 端末を用いて、2 つのデバイス間の距離を 1m おきに変化させ、各端末に関して 25 回ずつ探索を行った。その概要を図 5.4 に示す。清水らの研究 [32] によれば、Bluetooth の探索時間は、端末検出率にあたり大きな変化をもたらすことが述べられている。この点に関して、上田らは、各売り場内において顧客の平均滞在時間は 1 分を切る事が明らかになっている [35] と述べている。そこで、店舗滞在時間の算出に伴い、店舗来店後、及び、閲覧終了後の時刻を出来るだけ早く把握させることも考慮し、一回の Bluetooth 起動における探索時間は、10 秒とした。

5.2.2 実験結果

実験の結果を図 5.5、表 5.1 に示す。グラフに示すように、端末間の距離が伸びるにつれて、RSSI 値が下がるとともに、端末検出の精度も下がることが伺える。特に、7m を越えた地点では、検出率が 80%を割る。しかし、その一方で、半径 6m 以内の範囲内であれば、90%以上の確率で端末の検出が可能であることが分かる。




図 5.4 : Bluetooth による端末検知可能性の実験概要

5.2.3 Bluetooth の受容性に関するセンシング可用性に関する考察

清水らの研究 [32] でも、周囲にある Bluetooth 端末の数と端末検出率に関する評価実験を行っているが、この時、8 割以上の発見率を近接センサとして実用性があるラインとし結論づけている。また、Japan Council of Shopping Centers の調査によれば、ショッピングセンター1つあたりの平均店舗面積は 14,789m²であり、そのうち、通路などを除くテナントの占める面積は約 39%であると述べられている。さらに1つのショッピングセンターあたりの平均テナント数は 49 店舗であるとも述べられていることから、テナント面積をテナント数で割ることにより、テナント一つあたりの平均面積は、

$$14789[\text{m}^2] \times 0.39 \div 49[\text{テナント}] = 118 [\text{m}^2/\text{テナント}]$$

となる。従って、各テナントの敷地形状がほぼ正方形であると仮定すれば、一辺の長さは約 10.8m といえる。そのため、半径 6m の範囲内であれば、店舗中央に店舗の ID を配信する Bluetooth 端末を配置することで、90%以上の高精度での検索が可能であり、それ以上の範囲で検出率が 80%未満へと大幅に下がる Bluetooth は、隣接店舗の ID を読み取る誤認識の可能性も低く、ユーザが立ち寄った店舗のログを取ることが可能である点で、有効な興味のあるセンシング手段であるといえる。

一方で、想定よりも広い店舗での応用や、店舗内に障害物が多いケースを考慮する場合、サ

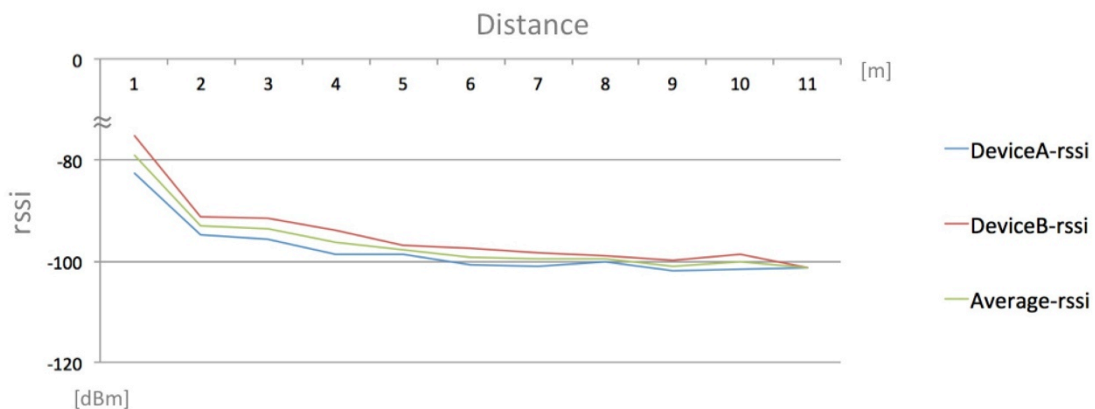


図 5.5 : Bluetooth による距離と端末検出率に関する実験結果

Distance	1m	2m	3m	4m	5m	6m	7m	8m	9m	10m	11m
rssi (dBm)	-78.96	-93.04	-93.5	-96.19	-97.76	-99.07	-99.60	-99.53	-100.96	-100.06	-101.27
Rate	98%	98%	100%	96%	96%	90%	78%	76%	88%	84%	66%

表 5.1 : Bluetooth による距離と端末検出率に関する実験結果

一歩となる店舗内の Bluetooth 端末数を増やすなど、最適な端末の配置が必要になるといえる。この際、Bluetooth 端末が増えることによる信号衝突の可能性はあるものの、本提案手法ではそのような信号衝突は起き難いと考えられる。たしかに、店舗情報習得における Inquiry mode による店舗 ID の探索手段は、通常の 1MHz の周波数 79 個を 1600[回/sec]でランダムにホッピングするのは異なり、ホッピングのパターンが 2 種類しかない、Inquiry hopping を行うため、信号衝突が発生しやすい。しかし、それを行うのはユーザのみであり、店舗側の Bluetooth 端末はブロードキャストのみを行うため、衝突を起こすことは考え難い。

さらに、ユーザのスマートフォン端末同士の干渉においても、Inquiry mode による探索を行うのは入店時の最初の 10 秒のみであることから評価を行ってみる。ここで、センシングが最も過酷な状況を想定し、日本最大のショッピングモールであるイオンレイクタウンでの実用を仮定して、ユーザ端末間の干渉が起きる可能性を考察してみる。イオンレイクタウンの基本情報は以下の通りである。

店舗面積	245,223m ²
年間来客者数	5,000 万人
テナント数	710 店舗
営業時間	10:00 – 22:00

また、図 5.6 に示すように、経済産業省による目的地別滞在時間の調査によれば、大型ショッピングセンターにおける来客者の滞在時間は、87.19 分である。Herb は、来店客が買い物にかかる時間のおよそ 80%は、商品を見たり購入するためでなく、単に売場から売場への移動に使わ




図 5.6 : 経済産業省による目的地別滞在時間の調査結果

れている [36] と述べている．このことから，実際にユーザが店舗内にいる時間は，その 1/5 の 17.44 分であるとみなすことが出来る．さらに，各売り場内において顧客の平均滞在時間は 1 分を切る事が明らかになっている [35] ため，ユーザは 1 分あたり 1 店舗に滞在するとすれば，ユーザ一人当たり，1 日に 710 店舗のうち 17.44 店舗を訪問すると言い換えることが出来る．従って，一店舗あたりのユーザの来店頻度は，

$$\frac{50000000}{365} \times \frac{17.44}{710} \times \frac{1}{(22-10) \times 60} = 4.672 \text{ [人/分]}$$

となり，1 分あたり 4.672 人が来店することとなる．つまり，12.84 秒に一人が各店舗に来店している計算となる．従って，Inquiry mode によって 10 秒間のセンシングをしている間に他のユーザが来店する可能性は低く，多くても高々 2 台が同時に店舗 ID の探索を行う程度である．清水らの研究によれば，探索時間 15 秒という条件下で，端末 2 台であれば約 95%，さらに，5 台であったとしても，80%以上の検出が可能である[32]ことが明らかとなっている．そのため，本提案手法において，10 秒の店舗 ID 探索による受容性に関する興味センシング中に，信号の衝突が起こる可能性は低く，Bluetooth は受容性に関する興味センシングに有用であると考えられる．

5.3 行動認識による省電力化の可能性

本実験では，特にリーセンサープランニングの受容性に関する興味ヒストグラム実現に際して行う，屋外での Bluetooth 起動における電力消費削減量で評価を行う．具体的には，提案手法と Bluetooth を常時起動して探索を行った場合，及び，加速度ノルムの分散のみに着目して Bluetooth を起動して探索を行った場合の二者と比べ，電池残量が 100%から 1%減少し，99%になるまでの時間を計測することで，提案手法により常時起動に対して何%の電力を削減出来たかという点で評価を行う．

5.3.1 実験方法

実験に際しては，Android 端末上に図 5.1 に示すフローに従って各センサを起動するアプリケーションの実装を行った．このアプリケーションによって得られた三軸加速度センサの値，及び，加速度ノルムの時間変化を図 5.7 に示す．サンプリングレート T_0 は 10sec，閾値 Thr_a は 2.20， Thr_w は 0.020 とした．これらの値は，図 5.9 の加速度ノルムの分散の変化，図 5.10 の歩行リズムの分散の変化に示すように，サンプリングレートを約 1.4sec 刻みで 4.2sec から 16.8sec までずらしていくことで，最適と考えられた値を経験的に定めた．（見やすさの観点から図 5.9, 図 5.10 では 5sec, 10sec, 15sec のサンプリングレートの結果しか表示していない．）歩行するルー

トに関しては、図 5.8 に示すような駒場第 2 キャンパス生産技術研究所内において、約 4 分間のシナリオに沿って、android 端末(Galaxy S3)を被験者 4 名に手に持った状態で行動してもらったことによってデータを収集した。シナリオについては、以下に示す通りである。

- 0sec ~ 60sec 店舗間移動
- 60sec ~ 120sec 店舗 A 閲覧
- 120sec ~ 180sec 店舗間移動
- 180sec ~ 210sec 店舗 B 閲覧
- 210sec ~ 240sec 店舗間移動

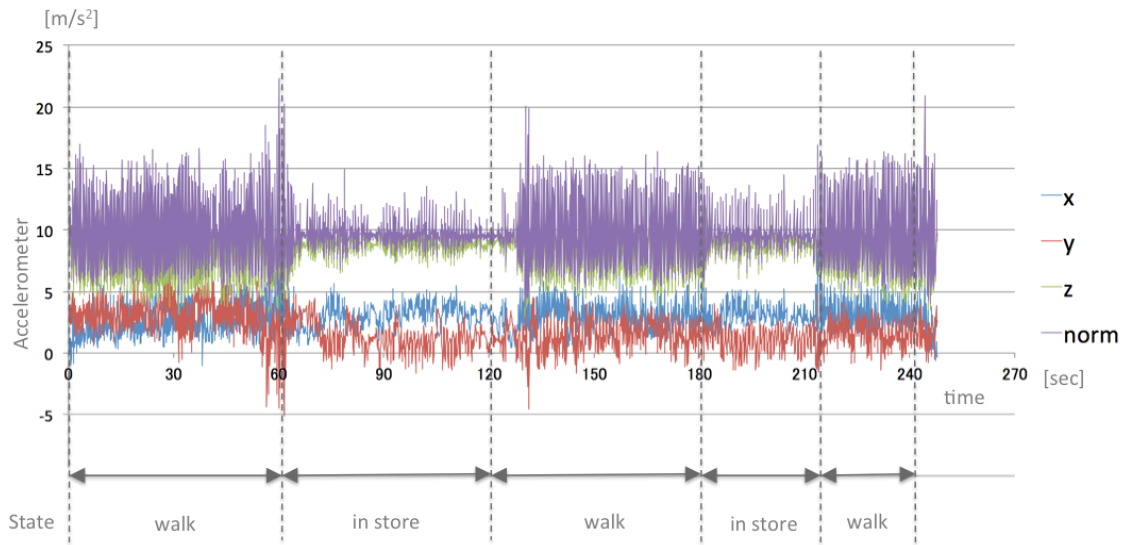


図 5.7 : 三軸加速度センサの値と加速度ノルムの時間変化の様子

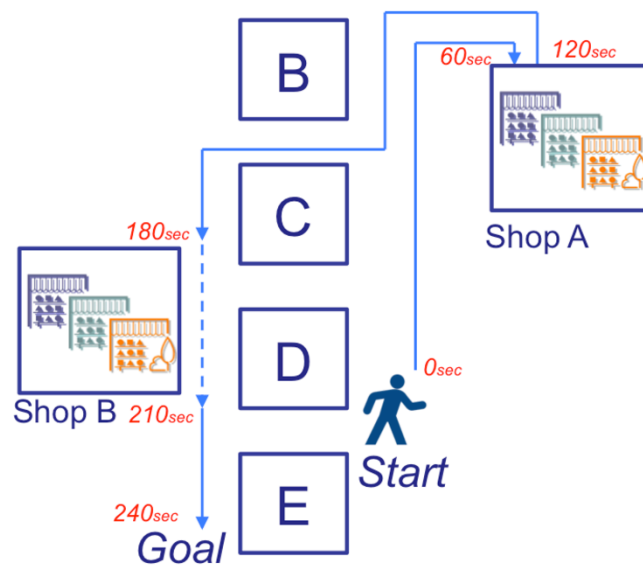


図 5.8 : 被験者の歩行シナリオ

シナリオの作成においては、各売り場内において顧客の平均滞在時間は1分を切ることが明らかになっている [35] ことから、各店舗の閲覧時間を1分以内に設定してすることとした。また、android 端末は、ユーザが歩きながら使っている状況を想定し、画面を上に向けた状態で手に持ってもらったこととした。実験に際して、端末は全ての通信機能を off とし、加速度センサと Bluetooth のみを起動させた。

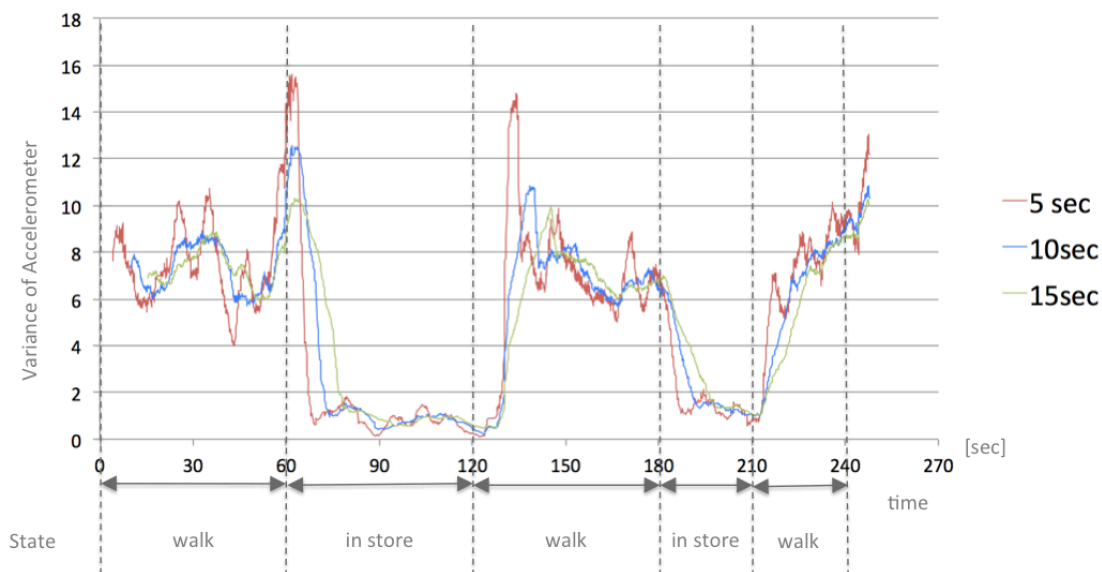


図 5.9 : サンプルングレートの違いによる加速度ノルムの分散の変化

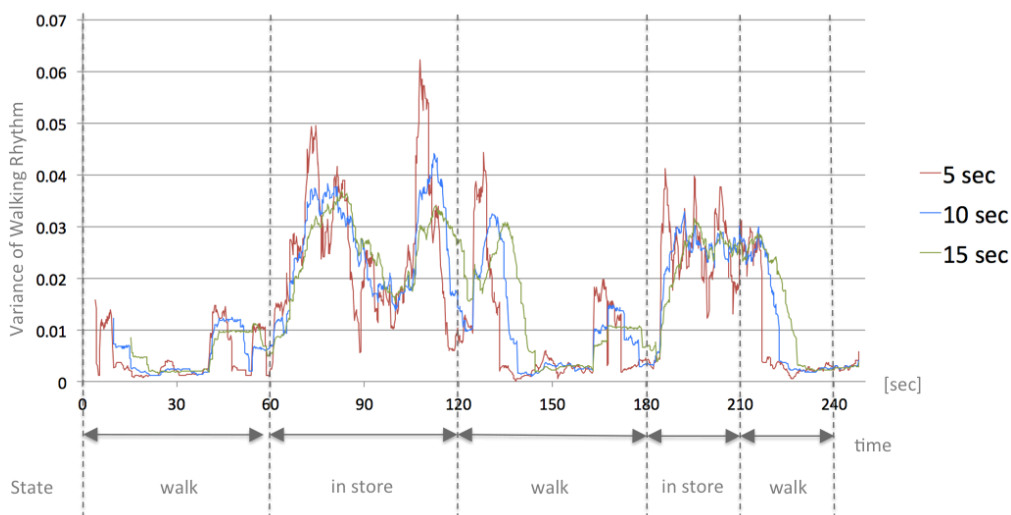


図 5.10 : サンプルングレートの違いによる歩行リズムの分散の変化

5.3.2 実験結果

この結果得られた、各被験者の加速度ノルムの分散を図 5.11 に、歩行リズムの分散を図 5.12 に示す。

実験の結果、加速度ノルムのみで歩行状態推定を行った場合には、被験者 4 人で、誤認識 11 回を含む、合計 19 回の Bluetooth 探索が行われたのに対し、歩行リズムを組み込んだ本提案手法では誤認識 1 回のみ合計 9 回の Bluetooth 探索が行われた。また、電池が 100% から 99% に 1% 減少するまでの時間は、常に Bluetooth 探索を行った場合は 927.377 秒だったのに対し、加速度ノルムのみで歩行状態推定を行った場合は 1176.053 秒、本提案手法で歩行状態推定を行った場合は 1372.541 秒であった。このように、本提案手法により、常に Bluetooth 探索を行った場合よりも 32.43%、加速度ノルムのみで歩行状態推定を行った場合よりも 14.32% の電力消費の削減を実現した。




図 5.11 : 被験者ごとの加速度ノルムの分散の変化

5.3.3 状態判別精度及び電力消費に関する考察

考察すべきポイントとしては3点着目すべき点がある。

まず一点目は状態検出の精度に関してだが、こちらは人の歩行するテンポに着目することで、特に「店内にいる」と誤検出が多かった 150-180sec 前後の検出における状態認識の精度の上昇が見受けられた。これは、人が角を曲がる前後で、歩く速度を落とすために一時的に歩行速度を落とした状態と、店内を見ている状態とを、加速度ノルムのみで判別することが難しくなっているものと思われた。一方、歩行テンポはコンスタントに刻んでいるために、歩行テンポ由来の分散値がさほど上がらなかったものと思われる。そのため、この二者を組み合わせることで、誤検出の割合を下げることに成功し、電力消費を抑えることに成功しているものと考えられる。

一方で、二点ほど課題も挙げられる。図 5.12 中 Sample A の分散値に着目すると、残りのサンプルの示す分散値に比べ、歩行テンポの分散値がかなり高めに出ていることが伺える。これは、加速度ノルムの間隔を拡大して検証したところ、他3つは sin カーブのようなコブが連続していたのに対し、Sample A のみは部分的にふたコブの山を生成していることが確認された。これがノイズなのか歩容特徴であるのかは今回の実験のみでは分からなかったが、今後さらに実装を重ねる上で実験を重ねながら考慮する必要があると思われる。

また、歩行リズムの分散値に、ある程度の傾向は伺えるものの、依然としてムラが多いことは事実である。この点に関しては、現在実装しているアルゴリズムでは、テンポ算出のポイン

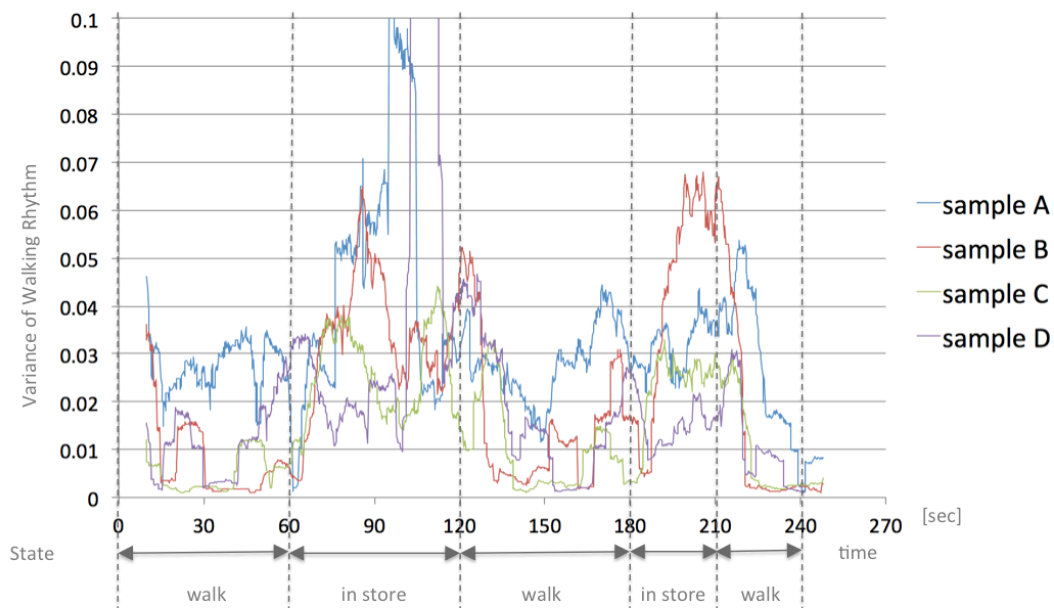


図 5.12 : 被験者ごとの歩行リズムの分散の変化

トが端末静止時の加速度 a_0 の時 1 点のみであり、分散値の算出に用いている数値はサンプルレート $T_0(=10\text{sec})$ 内に約 20 個程度しか存在していない。このことが原因となり、精度の甘さが出ているものと考えられる。そのため、android 端末内で遅延が発生しない情報量という制約の中で、今後テンポ算出のポイントを増やすなどの方法で精度を上げることが期待出来る。

このように、今回の実験によりまだいくつか課題は見えながらも、提案手法により Bluetooth を常時起動したときに比べ、約 32.43%の電力消費削減を実現し、今後さらに精度の高い状態推定及び省電力の可能性があることを実証した。

5.4 受容性に関する興味センシングのまとめ

本章では、リーセンシープランニングにおける受容性に関する興味センシングを行うための手法を提案した後、Bluetooth の受容性に関する興味センシングへの可用性に関して、実験を通して評価を行い、さらに、加速度センサを組み合わせることによる、センシングの際の電力削減可能性について評価実験を行った結果について考察を行った。

提案手法においては、人が各個人によって異なる歩容特徴を示す[34]ため、ある一定時間内の加速度の分散と歩行のリズムの周期に着目すれば、「店の前を通行しているとき」と「店内を見ているとき」で大きな変化が見られると考えた。そこで、「店内を見ているとき」のみ Bluetooth を起動させるため、人の歩行状態、特に加速度ノルムと歩行のリズムの変化を組み合わせることによる状態推定手法を提案した。

Bluetooth の受容性に関する興味センシングへの可用性に関しては、半径 6m の範囲で安定したセンシングが可能であり、店舗の広さに対して十分なセンシング能力を持っていることを示した。さらに、プライバシーに配慮し、ユーザがブロードキャストを行わず、Inquiry mode でセンシングを行う際の信号衝突の可能性に関しても、10 秒間の ID 検索をする上では問題にはならず、本提案手法における受容性に関する興味センシングにおいて、Bluetooth が有用であることを示した。

センシングの際の電力削減可能性に関しては、加速度ノルムと歩行のリズムの分散を組み合わせることで状態推定を行う本提案手法により、常に Bluetooth 探索を行った場合よりも 32.43%、加速度ノルムのみで歩行状態推定を行った場合よりも 14.32%の電力消費の削減を実現した。

このように、本提案手法により、屋外広告配信に際しての興味情報収集において課題となる、プライバシーの問題、及び、センシングにおける電力消費の課題を解消しながら、受容性に関する興味センシングを実現することが可能となる。

第6章 近接性に関する興味センシング

6.1 近接性に関する興味センシングのフロー

TV という広告媒体は、統計学的にも、脳科学的にも、人の興味・関心に大きな相関が認められるメディアの一つである [16], [17], [18], [19]. さらに屋外広告との大きなシナジー効果が認められるという点から、アウトオブホームメディアの領域と TV の領域を組み合わせ、クロスメディアの広告配信の手法は、人の購買行動に大きな影響を与えることが可能であると期待することが出来る。

上記背景から、本研究ではリーセンサープランニングにおける近接性を実現するため、屋外広告と相性の良い TV 広告を題材として、低演算かつプライバシーへの配慮をしながら、ユーザの TVCM 視聴履歴を能動的なインプット無しに記録する手法を考える。このような TV 視聴履歴を解析する手段として、ユーザとスマートフォンは約 90% という高確率で同じ場所に存在する [23] ことから、我々は、スマートフォンのマイクを用いることで、近接性に関する興味情報を自動的に収集することとした。

しかし、第2章で、TVCM の分類や解析においては高度な演算が必要であるということが指摘されているように、一般的にスマートフォン上でそのような高度な処理を実現することは難しい。一方で、TV 番組の放映にあたり、番組コンテンツのみならず、TVCM についても、放映以前に、何時にどの TVCM を流すのかということについての番組表が存在している。

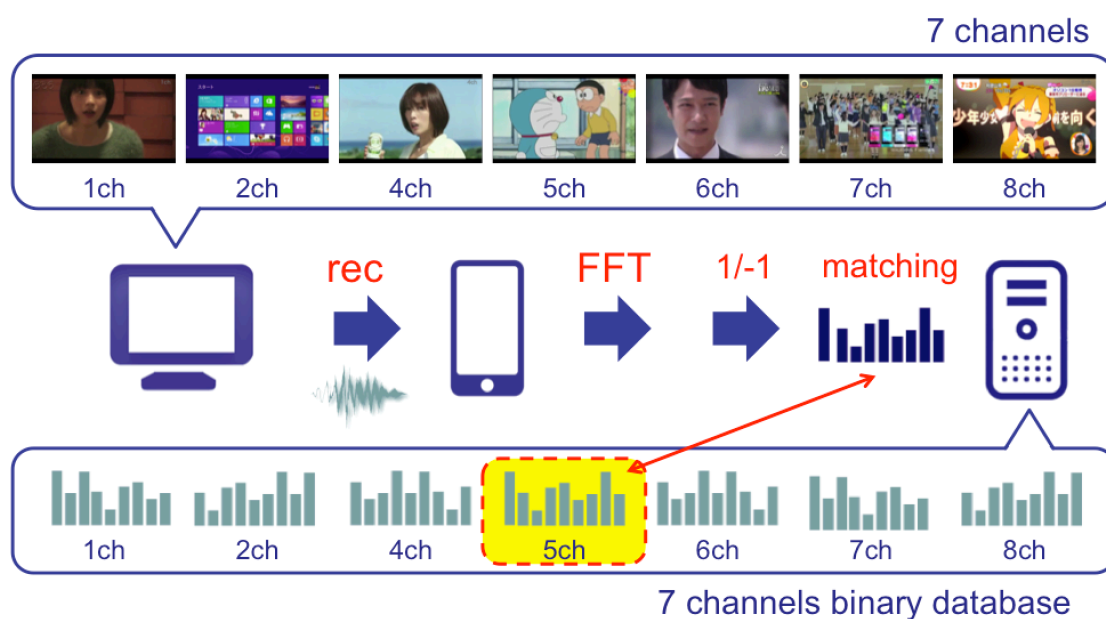


図 6.1 : 近接性に関する興味センシングの概要

そこで、本研究では、この番組表データを用いることで、視聴番組の解析におけるデータマッチング対象を限定し、音声データの特徴量をスマートフォン上で二値化することによって、プライバシーに配慮しながら低演算でマッチングを行い、視聴番組を推定する手法を提案する。その概要を図 6.1 に示す。

6.1.1 TV コンテンツの特徴量抽出

提案手法としてはまず、放送されている TV コンテンツをサンプリングレート T_m で録音する。次に、この取得データを 2^S サンプルごとに、高速フーリエ変換(Fast Fourier Transform, FFT)によって周波数変換する($F_0, F_1, \dots, F_f, \dots, F_{(2^{S-1}-1)}$) ($\ast 0 \leq f \leq (2^{S-1}-1)$)。その後、周波数分布の波形変化に着目し、 2^{S_m} サンプルおきにサンプリング周波数の度数比較を行い、1,-1 に二値化することで特徴量 B_f を抽出する。この特徴量抽出の概要を図 6.2 に示す。

$$\text{if } F_{f+S_m} \geq F_f \quad \dots \quad B_f = 1$$

$$\text{if } F_{f+S_m} < F_f \quad \dots \quad B_f = -1$$

また、データベースの生成にあたっては、サンプリングレート T_m で記録された、TV コンテンツオリジナルのモノラル音源を用いて、同等の演算処理を行うことで各 TV コンテンツのチャンネル ch の周波数分布データベース $Fdb_{(ch,0)}, Fdb_{(ch,1)}, \dots, Fdb_{(ch,f)}, \dots, Fdb_{(ch, 2^{S-1}-1)}$ ($\ast 0 \leq f \leq (2^{S-1}-1)$) を生成し、特徴量 $Bdb_{(ch,f)}$ の抽出を行った。

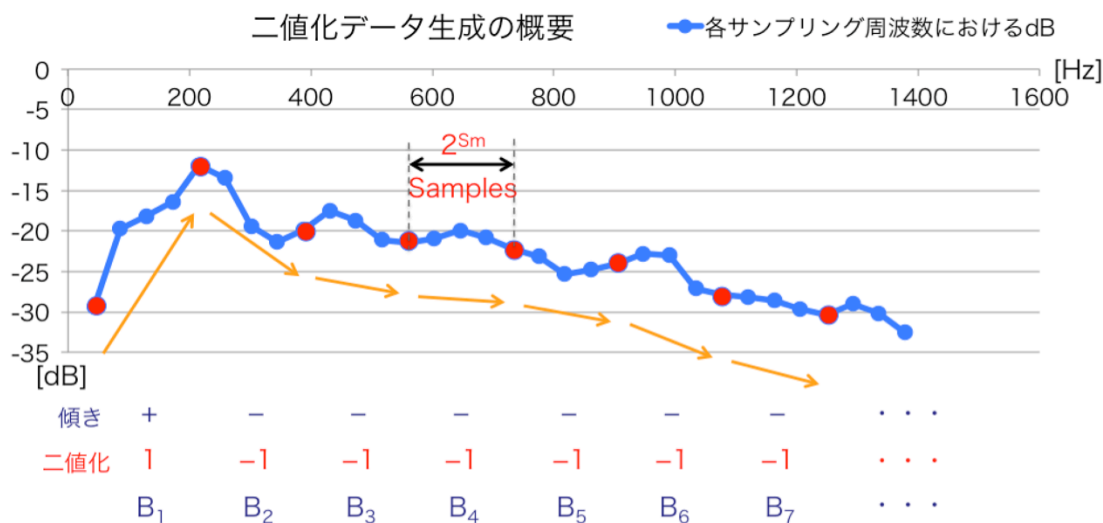


図 6.2 : 二値化特徴量生成の概要

6.1.2 演算の並列化

上記の特徴量抽出の演算をスマートフォン上で実装するにあたり、FFT (=Fast Fourier Transform) をリアルタイムに行いながら特徴量の生成を行うことは一般に難しい。そのため、本稿の提案手法では、録音後の FFT 及び特徴量の生成において、スレッドを用いて、8 並列の演算処理を行うことで、リアルタイムに特徴量の生成を行うことを実現した。その概要を図 6.3 に示す。

録音まではシングルスレッドで行い、モノラルのデータを習得する。その後、 2^{Sm} サンプルごと、つまり、 $2^{Sm}/T_{fft}$ 秒ごとに取得した音声データを FFT によって周波数変換してゆく。この演算は、録音の処理よりも時間がかかるために、シングルスレッドで行うとリアルタイムでの特徴量生成が出来ない。そのため、ここから先の作業においてスレッドを用いて並列処理を行い、リアルタイムでの特徴量生成を実現した。特徴量生成において、スレッド自体は制限無しに生成出来る一方、スマートフォンに搭載されている CPU は、最新のものでも、最大 8 スレッドまでの並列処理が限界であることから、8 並列としている。このように、並列で演算を処理することにより、本来シングルスレッドでは行えなかった処理も、リアルタイムに処理を実行することが可能となる。

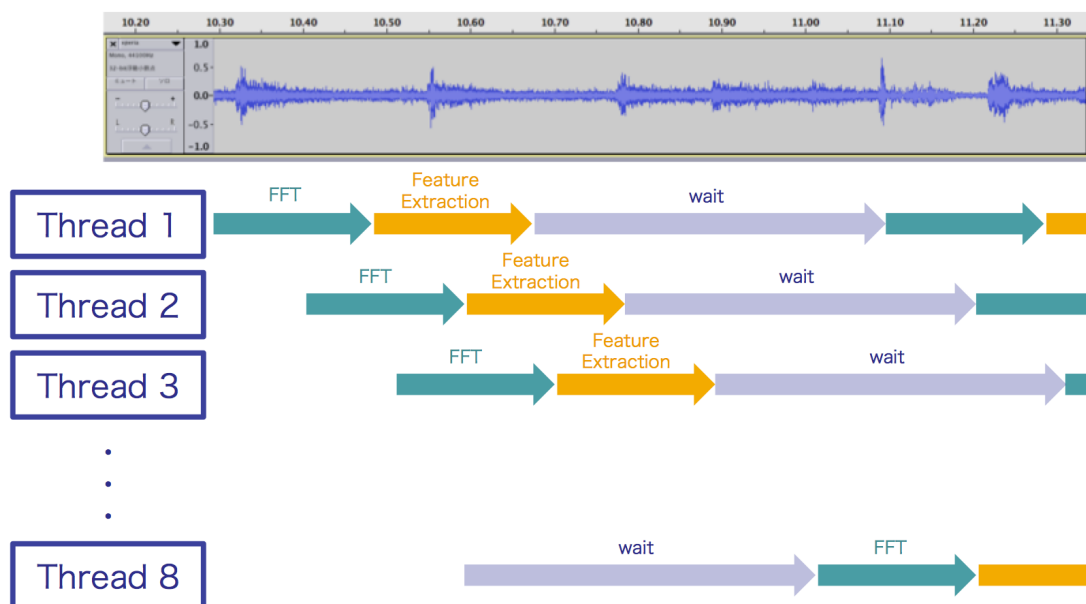


図 6.3 : 特徴量生成におけるスレッドを用いた並列処理の概要

6.1.3 特徴量のノイズ除去

FFT による周波数変換を行うことで、周波数ごとの信号の大きさが分かるが、その大きさには周波数ごとにかなり大きな差が存在する。その様子を図 6.4 に示す。録音によるもの(=F)も、オリジナルの生データ(=Fdb_(ch,t))も、共通して低周波数帯における信号強度と高周波数帯における信号強度との間には 20~30dB ほどの差が存在する。このような特に高周波数帯に見受けられる小さな信号はノイズを含みやすく、二値化処理を行う際に、大きなノイズに変化し、精度を著しく低下させる可能性がある。そこで、本提案手法では、データベースの生成において、特徴量の抽出後、Fdb_(ch,t)の平均値よりも度数の小さな特徴量データについては 0 に置換する処理を行うことで、小信号中のノイズの除去を行った。

$$if \quad Fdb(ch, f) \leq \frac{\sum_{f=0}^{2^{S-1}-1} Fdb(ch, f)}{2^{S-1}} \quad \dots \quad B_f = 0$$

6.1.4 マッチングによる TV コンテンツ推定

本節では、前節で生成された、各チャンネル *ch* の特徴量データベース、及び、録音によって得られた特徴量データを用いてマッチングを行い、視聴番組を推定する手法について述べる。その概要を図 6.5 に示す。録音によって生成された特徴量と同様にして生成されたサーバ上の各 TV コンテンツのチャンネル *ch* の特徴量データベース *Bdb*_(ch,0), *Bdb*_(ch,1), ..., *Bdb*_(ch,l), ...,




図 6.4 : 各周波数における信号強度

$Bdb_{(ch, 2^{S-1})}$ ($\ast 0 \leq f \leq (2^{S-1}-1)$)と、録音によって得られた周波数分布データベース($B_0, B_1, \dots, B_f, \dots, B_{(2^{S-1}-1)}$) ($\ast 0 \leq f \leq (2^{S-1}-1)$)に関して、同じサンプリング周波数における特徴量同士を、 N_{frame} フレーム分掛け合わせるにより、マッチングを行う。マッチングするデータベースのデータの参照に際しては、番組表データをもとに、タイムスタンプを用いて時間の調整を行った。

$$\text{チャンネル } ch \text{ の近似度数 } V_{ch} = \sum_{i=1}^{frm} \sum_{f=0}^{2^{S-1}-1} B_f \times B_{db(ch,f)}$$

この時、特徴量データベースの周波数分布波形と、録音によって得られた周波数分布波形の増減が一致している場合は1、不一致の場合は-1、信号の大きさが小さくノイズとして考えられるものについては0が返ることとなる。そのため、波形が近いものであればある程、この演算によって得られる度数が高くなる。この度数を各チャンネル ch の近似度数 V_{ch} とすることで、最大値を返したものを視聴チャンネルとみなすことが出来る。最後に、そのチャンネルの番組表データと時間とを照らし合わせることで、視聴番組及び視聴 TVCM の推定が可能となる。

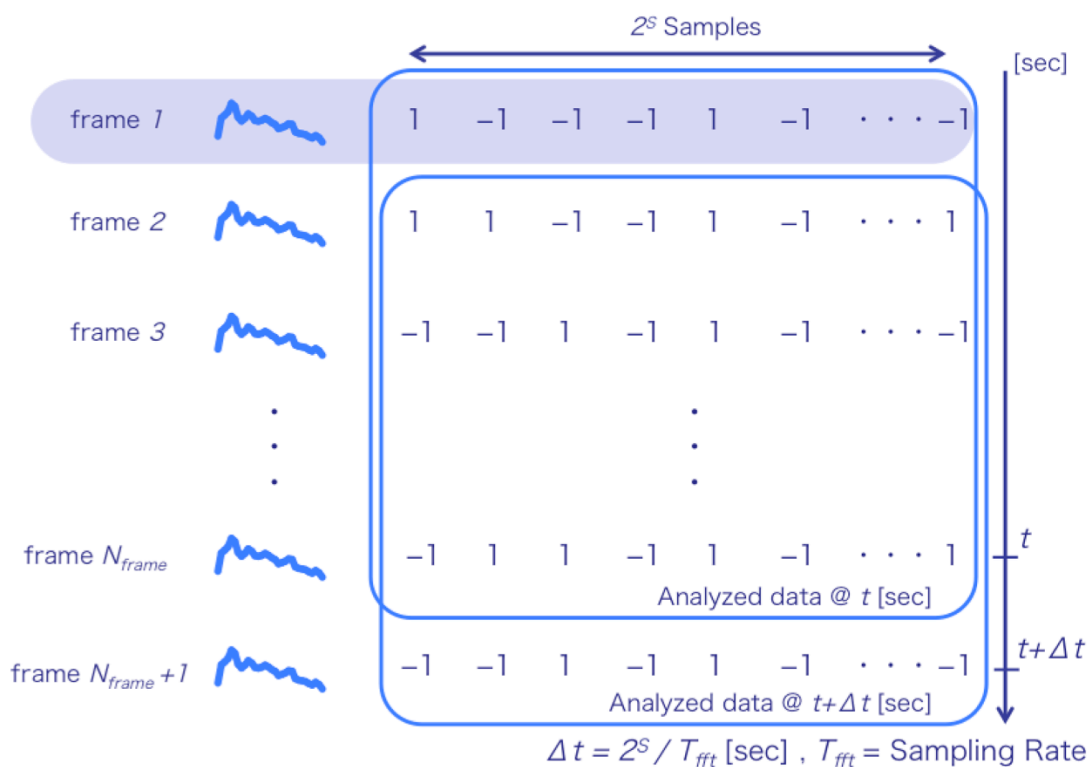


図 6.5 : TV コンテンツ推定における特徴量マッチング

6.1.5 近接性に関する興味ヒストグラムの生成

前節における番組コンテンツ推定の結果、最も周波数分布の近似度が高かったものを視聴された TV コンテンツと認識したのち、スマートフォンに TV コンテンツの ID(= k_ID)とカテゴリーの情報(= s)を送ることで、近接性に関する興味ヒストグラムの生成を行う。TVCM の視聴を元にした興味ヒストグラムの生成においては、ドイツの経済学者 Gossen が提唱している限界効用理論 [37] をもとに、ユーザの TVCM に関する興味度合いを定量化することを考える。

限界効用理論で述べられている限界効用(= $MU(x)$)とは、モノやサービスなどの“財”(= x)を 1 単位追加して消費することによるメリットである“効用”(= $U(x)$)の増加分を表す。この中に述べられている限界効用逓減の法則は、一般に、財の消費量 x が増えるにつれて、財の追加消費分(=限界消費分)から得られる効用 $MU(x)$ は次第に小さくなる、とする考え方であり、経済学の分野で広く用いられている法則の一つである。

$$MU_{(x)} = \frac{dU_{(x)}}{dx} > 0$$

$$\frac{dMU_{(x)}}{dx} < 0$$

例えば、飲み会で、最初に飲む 1 杯目のビールはとても美味しく感じる一方、2 杯目は 1 杯目ほど美味しくはなく、3 杯目は 2 杯目ほど美味しい訳ではない、というように 1 杯目、2 杯目、3 杯目と、数を重ねれば重ねるほど、ビールという財から得られる効用は小さくなることを表している。このように、消費量と効用の大きさの関係を表す効用関数のグラフでは、効用曲線は上に凸の右上がりとなり、上昇が次第に鈍化する。

この考え方をベースとして、Kong らは、配信するコンテンツ C_s を目にするのが j 回目であるユーザ c の配信するコンテンツ C_s に対する興味 $I_{c,j}(C_s)$ は以下の式であらわされるとしている [38].

$$I_{c,j}(C_s) = \begin{cases} j^{-2} & \text{if user } c \text{ is interested in } C_k \\ 0 & \text{otherwise} \end{cases}$$

つまり、この場合、限界効用と効用に関して、

$$MU_{(j)} = \frac{1}{j^2}$$

と書ける．これを積分することにより， j 回目にコンテンツを見たことのあるユーザ c の，そのコンテンツ C_s に関する興味の数値 $I_c(C_s)$ を算出することが出来る．本提案手法でも，この考えをもとに，TVCM を見た回数をもとに興味ヒストグラムの生成を行う．今回は，そのコンテンツに関する興味の数値を $0 \sim 2$ の間で表させるため，積分区間は $1 \sim j$ として計算を行う．ただし，計算の都合上，一度もそのコンテンツを見たことのないユーザのそのコンテンツに対する興味の数値は -1 とする．

$$U_{(j)} = -\frac{1}{j}$$

$$I_c(C_s) = \begin{cases} 2 - \frac{1}{j} & \text{if } j \geq 1 \\ 0 & \text{if } j = 0 \end{cases}$$

この値を，コンテンツのカテゴリ別に足し合わせることにより，カテゴリ s に対する，ユーザ c の近接性に関する興味ヒストグラムの生成が可能となる．

$$k_{s,c} = \sum I_c(C_s)$$

6.2 評価実験概要

本稿で提案した手法について，チャンネル特定のマッチング精度について評価実験を行った．実験に際しては，番組コンテンツと TVCM を組み合わせ，約 3 分の番組プログラムを 7 チャンネル分作成した．チャンネル数を 7 つに絞った点に関しては，図 6.6 に示すように，ビデオリサーチ社の調査で，TV チャンネル，視聴時間において地上波放送 7 チャンネルが圧倒的な割合を占めている[39]こと，及び，表 6.1 に示すように，イタリアでも，150 チャンネル以上が放映されているにもかかわらず，70%以上の視聴者が 7 チャンネルに集中している[40]ことから，評価実験に用いるチャンネル数を 7 チャンネルに限定した．番組プログラムには図 6.7 に示すように，ドラマ・アニメ・バラエティ・NEWS・CM をバランスよく混ぜ，内容に偏りが出ないように配慮した．実験に際しては，パソコン上で再生している番組に対して，正しいチャンネルを提示した時間を計測することで，マッチングの精度を評価した．実験場所としては，図 6.8 に示すような，4[m]×7.2[m]×2.6[m](縦×横×高さ)の鉄筋コンクリート製の建物内の一室を使い，部屋

に設置された机の端に PC を設置した後，そこから Length[m]離れたところに携帯端末を置いて計測を行った．また，マッチングに際しては，事前に携帯端末内にサーバから送られた参照データベースがあるものと仮定し，携帯端末内にデータベースのインプットを行った．録音に際しては， $T_{\text{fft}} = 11025\text{Hz}$ で録音し，この取得データを $2^s = 1024$ サンプルごとに，高速フーリエ変換を行った．各実験においては，図 6.2 に示すように，二値化を行う際に何サンプルごとに二値化を行うのかという間隔 2^m を，1 サンプルごと，4 サンプルごと，16 サンプルごとの 3 パターンと，それらの組み合わせの合計 5 パターンで変化させ，解析精度にどのような違いが生じるか評価を行った．

上記評価実験に際し，本稿では，3つの実験を行った．

- i) 距離による精度変化
- ii) 解析フレーム数による精度変化
- iii) チャンネルごとの精度変化

その実験の結果について以下の節で述べてゆく．

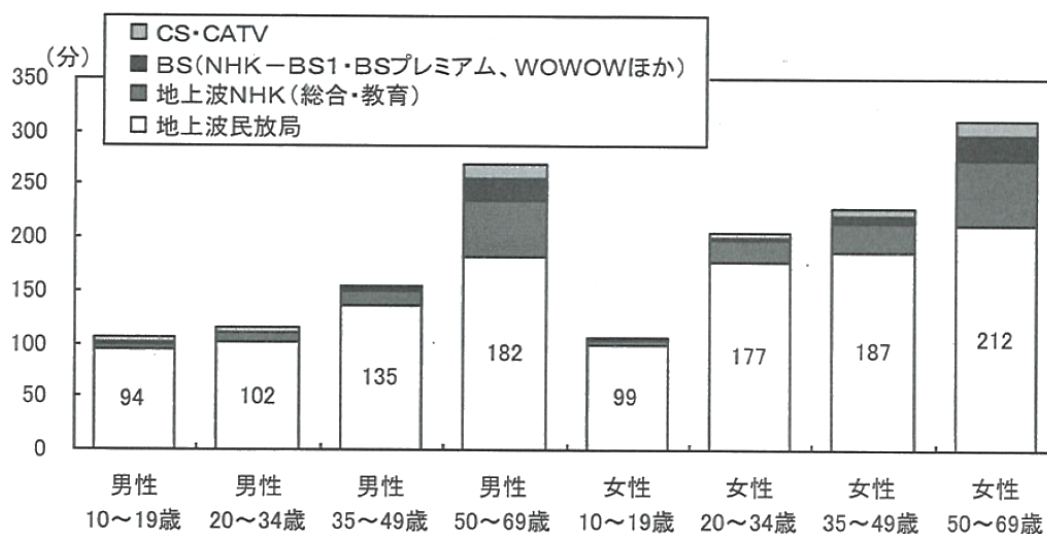


図 6.6 : 年齢別 TV 視聴時間 (週平均) の違い [39]

Channel Name	Share of TV watchers
Rai 1	18.55%
Canale 5	16.39%
Rai 3	9.29%
Italia 1	8.88%
Rai 2	8.67%
Rete 4	6.39%
La 7	5.42%
Total	73.59%

表 6.1 : イタリアにおける視聴率の高い 7 チャンネルの視聴比率 [40]

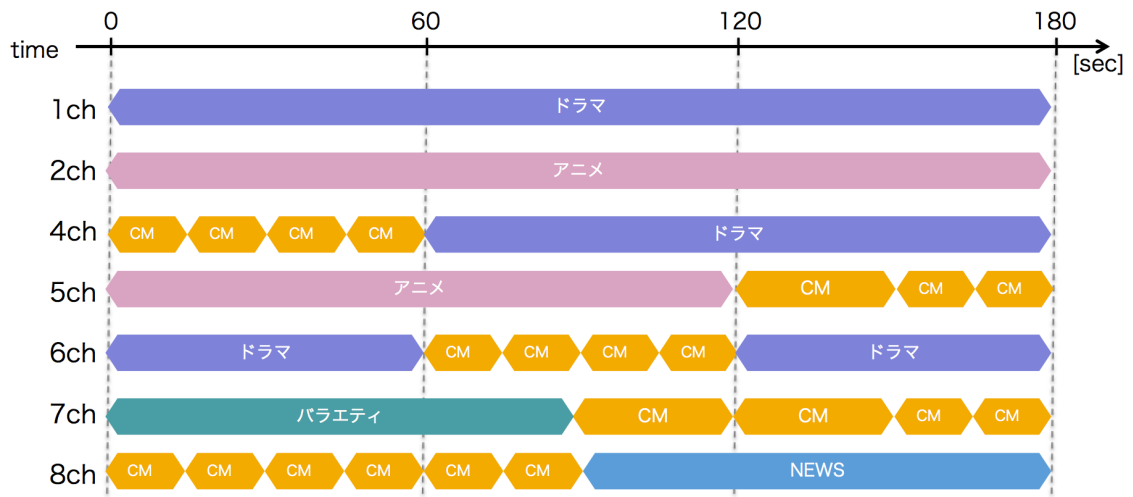


図 6.7：実験に用いた番組プログラム




図 6.8：実験に用いた部屋

6.3 距離による精度変化

6.3.1 実験方法

距離による精度変化に関しては、図 6.8 に示すように、番組コンテンツを流す PC と携帯端末との距離(=Length)を 0.5m~5m の間で変化させた。各距離において携帯端末で録音を行い、正しいチャンネルを示していた時間を計測することにより、マッチングの精度の評価を行った。また、解析フレーム数は $N_{frame} = 80$ として実験を行った。

6.3.2 実験結果

距離による精度変化の様子を図 6.9 に示す。各二値化特徴量生成パターンにおいて、いずれも音源となる PC と、録音する携帯端末の距離が長くなるにつれて精度が下がっていることが見受けられる。特に、オレンジの破線で示す 1sample ごとに二値化を行った場合には、音源からの半径約 2m 以内では 80%以上の解析精度を維持出来る一方で、それ以上の距離になった場合には大幅な精度の低下が起きている。一方、二値化におけるサンプルの間隔数を 4,16 と大きくするにつれ、同じ演算量にも関わらず精度が大幅に上昇していることが見て取れる。特に、5m 離れた地点における解析精度は、1sample ごとに二値化処理を行った場合に比べ、青い点線で示す 16sample ごとに処理を行うことで 19.9%の精度向上に成功している。また、赤い実践で示すように、これら 3つの処理データを組み合わせて解析を行うことで、30.6%の精度を向上さ




図 6.9 : 特徴量生成時のサンプリングレート毎の距離によるマッチング精度変化

せることが出来た。精度の観点からも、半径 3m 以内であれば、常に 96%以上の精度を保っており、かつ半径 5m 地点においても 79.95%という解析精度を保持している。

6.3.3 センシングの距離耐性に関する考察

一般に、suumo の調査によれば、20 代社会人の一人暮らしの部屋の専有面積の平均は 27.4m² であると言われている（この中には居間のみではなくキッチン、トイレ等も含む）。従って、部屋自体が正方形であると仮定すれば、居間一部屋の一边の長さは高々 5m である。そのため、TV から 5m 以内で高精度な認識が出来れば、実用には十分な精度を担保出来ると言って差し支えない。そのため、考察も実験で行った、半径 5m 以内における精度についての評価のみで十分であるものとする。

まず、全体的な傾向として見受けられた、距離が伸びたことによる精度の低下について考察を行う。点音源における音圧を P_0 とし、距離 r_1 における音圧レベル L_1 の距離減衰を表す式は以下で与えられる。

$$L_1 = 10 \log \left(\frac{P_1}{P_0} \right)$$

また、距離 r_2 における音圧を P_2 は、 P_1, r_1, r_2 を用いて以下のように書ける。

$$P_2 = P_1 \left(\frac{r_1}{r_2} \right)^2$$

従って、音圧は距離の 2 乗に反比例して弱くなり、距離 r_1 における音圧を L_1 とすると、距離 r_2 における音圧を L_2 は、以下のように書ける。

$$L_2 = L_1 - 20 \log \left(\frac{r_2}{r_1} \right)$$

従って、TV から 1m の距離における音圧と比較して、

3m 地点における音圧：	-9.54dB	1/9 倍
4m 地点における音圧：	-12.04dB	1/16 倍
5m 地点における音圧：	-13.98dB	1/25 倍

となる。

このことを踏まえ、特に、3mをひとつの区切りとして、距離が伸びるにつれて精度が大幅に低下したことを考えると、TVから約1mの地点における音圧から、約1/10倍以下に音圧が低下すると、精度が大幅に減少すると言いうことが出来る。これは、距離が伸びるにつれた音圧低下に伴い、二値化特徴量生成における二つのデータ間の各周波数の度数間に逆転が生じたためと考えられる。また、距離による精度減少の度合いに関しては、二値化に際して、複数のサンプリングレートを用いることにより、その減少の度合いを押さえることが出来ると言いうことが伺える。

次に、二値化特徴量生成におけるサンプリングレート変化による精度向上について、考察を行う。特に、赤の実線で示す、3つの処理データを組み合わせる解析を行った場合について、半径3m以内であれば、常に96%以上の精度を保っており、かつ半径5m地点においても79.95%の精度を保っている。この点については、清水らの研究 [32] でも、8割以上の発見率を近接センサとして実用性があるラインとし結論づけているように、カテゴリーの判別をするという点では十分な解析精度を保持しており、日常の屋内の部屋における興味情報取得に際し、本アルゴリズムが実用に堪えると言いうことが出来る。青の点線で示す16sampleごとに処理を行った場合でも、赤の実線のものに比べ、演算数が1/3で5mはなれた地点で約75%の精度を保っていることは、精度の高い解析結果を示していると言いうことが出来る。また、1sampleごとに二値化特徴量生成を行った時に比べ、広い間隔で二値化特徴量生成を行った時の方が、精度が向上した点については、近いサンプリング周波数同士を比較して二値化特徴量を生成すると、非常に近い周波数帯の二つ同士が似たような度数を示すため、二者間で度数の逆転が生じたためと考えられる。これが、サンプリング周波数を広げた場合は、図6.4に示すように、高周波数帯と低周波数帯で、度数に大きな差が生じるため、このような度数の逆転が生じ難かったと考えられる。しかし、一方で、この間隔が広すぎる場合は、二値化特徴量生成時にどのチャンネルにおいても似たようなデータベースが生成されてしまうため、かえって精度が減少してしまう可能性が考えられるため、ほどよいサンプリング間隔で二値化特徴量を生成する必要があると言いう。

6.4 解析フレーム数による精度変化

6.4.1 実験方法

解析フレーム数による精度変化に関しては、図6.5に示すように、 T_{fit} で録音した取得データを 2^8 サンプルごとに、高速フーリエ変換する一連のフローによって得られた二値化データを1フレームとし、解析に用いるフレーム数 N_{frame} を変化させ、精度の評価を行った。

6.4.2 実験結果

マッチングにおける解析フレーム数による精度変化を図 6.10 に示す。今回の実験では解析フレーム数 1 つあたりの時間は、 $2^S / T_{fit}$ ($\sim 0.0929\text{sec}$)となる。このフレーム数をどれだけの数だけ解析にかけるかにより、精度に変化が見られた。各二値化特徴量生成パターンにおいて、いずれも解析フレーム数が多くなればなるほどマッチングの精度が単調増加で上昇することが見受けられる。1sample ごとに二値化を行った場合は、80 フレーム(~ 7.4 秒)分を解析にかけても 51.9%の精度しか出なかったのに対し、1sample ごと、4sample ごと、16sample ごとの、各々二値化処理をしたものを組み合わせて解析を行った場合は、前者の 1/4 の 20 フレーム(~ 1.9 秒)分を解析にかけただけで、68.3%の精度を出すことが出来ている。また、同数の 80 フレーム分を解析にかけた場合も、91.1%という高精度での解析が可能となっている。

6.4.3 マッチングにおける解析フレーム数に関する考察

精度の観点から考察していくと、単純な人の興味のヒストグラムの生成という観点では、80 フレームを解析に用いてマッチングを行うことで、90%の精度という、興味ヒストグラムの生成には十分な精度を担保出来るということが出来る。さらに、このフレーム数を上昇させることで、さらなる精度の上昇が見込める。しかし、その一方で、TVCM 一つあたりの時間が、短い

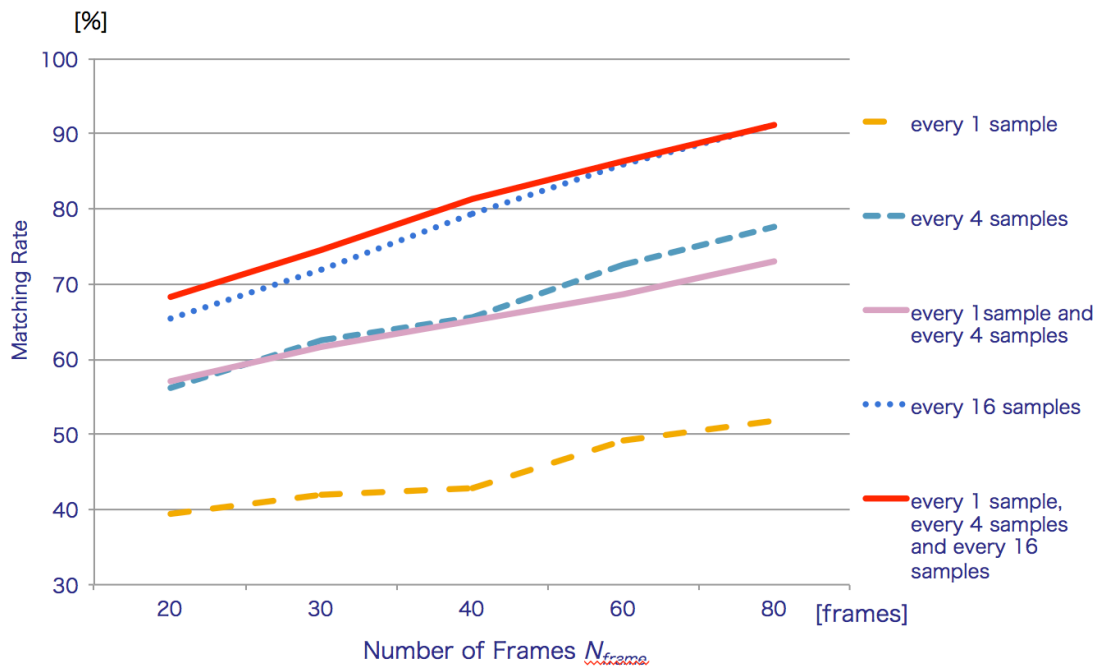


図 6.10 : 解析フレーム数による精度変化

もので 15 秒であることを考慮すると、チャンネルの切り替え等を行った際に、チャンネルが変わったことを認識するのに時間がかかったり、解析に際しての演算コストが嵩んでしまったり、と言った問題点が生じるため、センシングの精度を高くキープしたい場合には、80 フレーム程度というのがちょうどよいバランスであると考えられる。

一方で、将来的に TV とスマートフォンといったマルチスクリーンでの広告配信への利用等を考える場合、解析による約 7.4 秒の遅延というのは非常に大きく感じる。しかし、これについては、コンテンツ配信前 7.4 秒を解析していることを踏まえ、7.4 秒後の映像コンテンツに対応した情報配信を行うことでカバー出来ると言える。しかし、この遅延は、チャンネルの切り替えに際しては大きく響いてくる。チャンネル切り替え後、解析に用いるデータ数の半分以上が、変えた後のチャンネルのコンテンツによるデータに置き換わるまでに、解析にかかる秒数の半分の秒数がかかるためである。従って、80 フレーム(=7.4 秒)を解析に用いる場合を例にとれば、チャンネル切り替え後、チャンネルの切り替えを認識するまでに、約 3.7 秒の遅延が生じることとなる。この点に関しては、チャンネル切り替え時の無音等、チャンネル切り替え時特有の特質を活かしたアルゴリズムの考案や、解析に用いる時間を短くしても精度が落ちないようにするためにアルゴリズムを改良する等、今後更なる改善が必要であると言える。

6.5 コンテンツの違いによる精度変化

6.5.1 実験方法

チャンネルごとの精度変化の実験に向けては、図 6.7 に示すような、各 3 分程度の 7 チャンネル分の番組を準備した。実験に際しては、チャンネルごとにマッチングを行い、正しいチャンネルを提示する時間の割合から精度の評価を行った。また、解析フレーム数は、前述のチャンネル切り替え等の遅延を減少させるため、あえて 80 フレームではなく、 $N_{frame} = 40$ として実験を行った。

6.5.2 実験結果

チャンネルごとの精度変化の実験結果を図 6.11 に示す。チャンネルごとの解析には 40 フレーム分ずつ解析にかけているが、赤、青で示す、16sample ごとに特徴量生成を行ったものを解析に含めた場合においては、5ch, 7ch, 1ch でどれもほぼ 90%以上という高精度な判別が可能となっている。一方、2ch, 及び 8ch は解析精度が 65%を割るという、精度を欠いた結果となっており、チャンネルごとに精度にばらつきが見られた。また、全体的な傾向として、やはり二値化特徴量生成におけるサンプリング間隔を広く取った方が、解析精度が上昇することが伺える。

6.5.3 コンテンツによる精度変化に関する考察

チャンネルごとに解析精度にばらつきが見られたことについて、特に、5ch,7ch の解析精度が高かった点に関しては、番組コンテンツの種類はバラバラであった一方で、比較的バックミュージックの多い番組構成になっていたことが大きな要因として考えられる。1ch もバックミュージックは少なかったものの、歌を歌うシーンが多かった点や、会話が絶え間なく続くシーンが多かった点が解析精度の高さに繋がったものと考えられる。一方、解析精度を欠いた 2ch, 8ch に関してはバックミュージックが少なかったことに加え、会話が比較的途切れがちなシーンが多く、無音が多かったことが精度の低さに繋がったと考えられる。実際、番組コンテンツの中でも、TVCM は比較的バックミュージックを含むことが多い。

そのため、本実験に加えて、TVCM と TV コンテンツ両方を含む場合と、TVCM のみで解析を行った場合の解析精度を比較するため、追加実験を実施した。その結果を図 6.12 に示す。この図に示すように、TVCM のみの場合の解析において、精度の向上が見受けられた。既存研究 [28]では、ASR 用いた解析においては、バックミュージックのノイズが含まれることにより、解析の精度が悪くなることが課題としてあげられていたが、番組表データを用いた本提案手法により、バックミュージック等を多く含む番組コンテンツのカテゴリライズによる興味情報の生成を高精度で行うことが可能となる。

さらに、今回は実装及び実証実験は出来ていないものの、番組表データの生成と同様に、近年、地上デジタル放送の発展に伴い、リアルタイムの番組コンテンツ配信に際し、字幕放送の




図 6.11 : チャンネルごとの精度変化

データもブロードキャストされている。このような字幕放送のデータをマッチングの際に利用することで、単なる番組推定のみならず、さらに高精度かつ詳細な番組コンテンツの推定が可能になると期待出来る。

6.6 近接性に関する興味センシングのまとめ

本章では、リーセンシープランニングにおける近接性に関する興味センシングを行うための手法を提案した後、距離・解析フレーム数・チャンネルごとに、どのように精度が変化するか評価実験を行い、その結果について考察を行った。

提案手法においては、この番組表データを用いることで、視聴番組の解析におけるデータマッチング対象を限定し、音声データの特徴量をスマートフォン上で二値化することによって、プライバシーに配慮しながら低演算でマッチングを行い、視聴番組を推定する手法を提案した。

距離に関する耐性においては、音源から半径 5m 以内では、常に約 80%の精度を出すことに成功しており、実用に堪えることを示した。

解析フレーム数に関しては、単純な興味ヒストグラムの生成のみを考慮すれば良い場合と、マルチスクリーン等の応用を考慮する場合で差はあるものの、40~80 フレームを解析にかけることで十分な精度が出せることを示した。

チャンネルごとの精度に関しては、ばらつきはあるものの、ASR 等による解析の難しい、音声複雑なコンテンツにおいて、90%以上という高精度な認識が可能となっていることを示した。

このように、本提案手法により、スマートフォンを用いた興味情報収集において課題となる、プライバシーの問題、及び、コンテンツ推定における演算コストの高さという課題を解消しながら、近接性に関する興味センシングを実現することが可能となる。

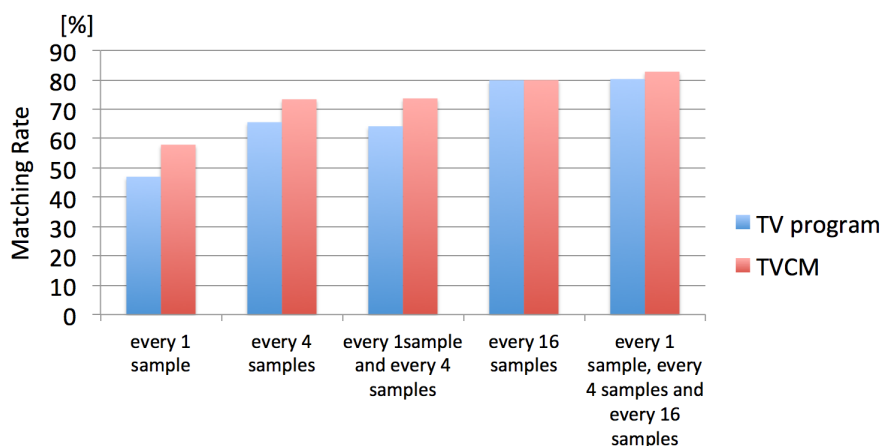


図 6.12 : TV 番組を解析した場合と TVCM のみを解析した場合の精度変化

第7章 適応型屋外広告配信に向けた考察

第5章、第6章で生成した人の興味ヒストグラムを元に、ユーザに対して適切な屋外広告コンテンツを配信することに関して考察を行う。前述した、受容性に関する興味ヒストグラム、及び、近接性に関する興味ヒストグラムを用いることで、コンテンツを配信するサイネージの前にいる通行人 n 人の興味パラメータを参照し、それらをカテゴリ別に足しあわせることで、サイネージ前にいるグループに着目したコンテンツの配信が可能となる。サイネージの前にいるグループの興味ヒストグラムの計算は、リーセンシープランニングの考えに即し、各個人に対して“今”興味のあるものに関するコンテンツを表示するため、近接性と受容性の両方を満たす必要がある。そのため、まず各個人のスマートフォン上で、ある通行人 c ($1 \leq c \leq n$) のカテゴリ s ($1 \leq s \leq m$) に対する近接性ベースの興味ヒストグラム $k_{s,c}$ と受容性ベースの興味ヒストグラム $j_{s,c}$ を掛け合わせ、カテゴリごとの興味ヒストグラムの総和で割った（各個人の興味の度数の最大値を1にしたら）ものを計算することで、通行人 c が“今”カテゴリ s に興味を持っていると考えられる度数 $i_{s,c}$ を計算する。

$$i_{s,c} = \frac{j_{s,c} \times k_{s,c}}{\sum_{s=1}^m (j_{s,c} \times k_{s,c})}$$

このように計算された $i_{s,c}$ を n 人分足しあわせて n で割るという手法をとることで、グループの興味の度数の最大値を1として、カテゴリ s に対するグループの興味の度合い I_s が算出される。

$$I_s = \frac{\sum_{c=1}^n i_{s,c}}{n}$$

また、計算された興味ヒストグラムのうち、最大値を示すカテゴリが最も配信効果が高いということが出来る。従って、配信すべきコンテンツのカテゴリ $C_{delivery}$ は以下のように表せる。

$$C_{delivery} = \max(I_s)$$

このようにして決定されたカテゴリ $C_{delivery}$ に属する広告コンテンツを、デジタルサイネージ内のサーバに貯蓄しているデータベースと参照して配信することで、“今”“目の前にいる”グループに対し、リーセンシープランニングにおける、受容性・近接性の双方を満たす、効果的な広告の配信が可能になると期待できる。

第8章 結論

本稿では、リーセンサープランニングの考え方に基づいた、適応型屋外広告配信のための実世界データを用いた人の興味センシング手法について述べた。

まず始めに、屋外広告の現状、購買理論について触れた後、屋外広告の中でも特にデジタルサイネージの抱えている課題について指摘を行った。特に、デジタルサイネージを用いた広告配信手法の課題として、プライバシーへの配慮、オンラインの興味情報への偏り、人による能動的なインプットの必要性という3点を挙げ、「オンライン上に現れない人の興味の収集手法の確立」及び「人の興味をベースにした個人のプライバシーに配慮した屋外広告配信手法の確立」が問題になっていることを指摘した。

次に、現状で効果的な手法が提案されていない、人の興味をベースにした興味収集手法及び屋外広告配信手法を確立する切り口として、リーセンサープランニングに関して、受容性・近接性という二つの概念を中心に紹介した。そして、それらの受容性・近接性をベースにした興味センシングによる広告配信システムを実現する上での課題点を指摘した。受容性の側面においては、店舗来店履歴データの取得を行うが、この際の課題としては、消費電力の削減・プライバシーへの配慮の二つを挙げた。また、近接性の側面においては、屋外広告と相性の良いTV広告を題材として、視聴したTVCMの分類を行うが、これをスマートフォン上で行う際の課題として低演算処理・プライバシーへの配慮の二つを挙げた。

そして、このような問題を解決する方法として、スマートフォンを用いることで人の能動的なインプットなしに、オフラインの行動のセンシングすることで興味情報を収集し、グループの興味にフォーカスした屋外広告配信システムの提案を行った。具体的には、リーセンサープランニングの考え方にに基づき、3軸加速度センサとBluetooth通信を組み合わせた店舗来店履歴把握による受容性、音量センサを用いたTVCM視聴履歴の把握による近接性、この2点の実現を考慮した上で、グループにフォーカスした適応型屋外広告配信のシステムを提案した。

受容性に関する興味センシングの実装にあたっては、「店内を見ているとき」のみBluetoothを起動させるため、人の歩行状態、特に加速度ノルムと歩行のリズムの変化を組み合わせることで、店舗間移動時と、店舗内閲覧時の2つの状態を推定し、Bluetoothの起動時間の短縮する手法を提案した。

近接性に関する興味センシングの実装にあたっては、プライベート空間でのスマートフォン利用を想定し、番組表データを用いることで視聴番組の解析におけるデータマッチング対象を限定し、音声データの特徴量をスマートフォン上で二値化することによって、プライバシーに配慮しながら低演算でマッチングを行い、視聴番組を推定する手法を提案した。

最後に各センサによる興味情報収集手法の精度、特に受容性の面に関しては省電力可能性、近

接性の面に関してはマッチング精度について評価実験を行い、適応型屋外広告配信に向けた考察を述べるとともに、本提案手法の有用性を示した。

本研究により、現在一方通行なコミュニケーションが指摘されている、デジタルサイネージを始めとした屋外広告配信システムにおいて、生活者の興味に合わせた適応型屋外広告配信が可能になる。また、本研究ではデジタルサイネージの前にいる複数のユーザの興味に応じた広告配信という、比較的ミクロな視点での屋外広告配信手法に関して提案を行ったが、関本らの提案している PFLOW [41] などの人流計測データと組み合わせることで、マクロな視点での効率的な屋外広告配信手法を確立することも望める。さらに、このような広告配信システムが街中のデジタルサイネージにインフラとして導入されることにより、生活者にとってより快適で心地よい「生活者を理解するスマートシティ」の実現が期待出来る。このようなより快適な生活や街づくりに向け、本研究がその一助となれば本望である。

謝辞

本修士論文は、筆者が東京大学大学院情報理工学系研究科電子情報学専攻修士課程に在籍中の、瀬崎研究室における研究成果についてまとめたものである。本研究を進めるにあたり、きめ細かくご指導・ご鞭撻をしていただき、大変お世話になりました。東京大学空間情報科学研究センター 瀬崎薫 教授に深く感謝し、厚く御礼申し上げます。研究への取り組み方や進めていく上での方向性、発表における見せ方を始め、研究のみならず日常生活におけるティップスに至るまで、研究のみならず精神的な部分まで大変大きなサポートをいただき、大変お世話になりました。また、学会発表におけるご指導を始め、研究に関することのみならず、多くのアドバイスをいただき大変お世話になりました。東京大学空間情報科学研究センター 小林博樹 助教、東京大学生産技術研究所 附属ソシオグローバル情報工学研究センター 伊藤昌毅 助教に厚く御礼申し上げます。加えて、研究を進めていく上で事務処理等において大変お世話になりました。秘書の松本夏穂様、内藤潤様に厚く御礼申し上げます。そして、研究を進めるにあたり、あらゆる視点から助言をくださっただけでなく、広い人脈を活かして様々な研究者の方にお会いさせていただける機会までいただきました。東京電機大学未来科学部 情報メディア学科 岩井将行 准教授に厚く御礼申し上げます。また、研究にあたり、様々なディスカッションを行うほか、プログラミングや研究の進め方において沢山の助言をくださった先輩方、瀬崎研究室で生活していく中で、研究のみならず、プライベートな面でも私を支えてくださった同期の皆様、実験協力を始め、研究室で生活していく中で私に大きなサポートをしてくださった、M1の皆様と、研究室の全ての方々に厚く御礼申し上げます。

最後に、2年間、ここには書ききれないくらいの、本当に沢山の方々の支えがあって研究を進めることが出来たこと、そして、この論文を執筆することが出来たことに感謝しながら、謝辞を締めくくらせていただきます。

発表文献

1. 木田裕一朗, 奥野淳也, 青木俊介, 瀬崎薫, “携帯端末を用いた TV コンテンツ推定によるユーザの興味センシング”, モバイルネットワークとアプリケーション研究会(MoNA), 2013年11月
2. 木田裕一朗, 奥野淳也, 青木俊介, 小林博樹, 岩井将行, 瀬崎薫, “リーセンサー効果を用いた適応型屋外広告配信のための興味センシング”, ヒューマンコミュニケーショングループ(HCG2013)シンポジウム, 2013年12月

参考文献

- [1] Drossos, D., and Giaglis, M.G., “Mobile Advertising Effectiveness: an Exploratory Study”, Proceedings of International Conference on Mobile Business, 2006.
- [2] Chang, K.T.T, and Wen Chen, Tan, B.C.Y, “Advertising Effectiveness in Social Networking Sites: Social Ties, Expertise, and Product Type”, IEEE Transactions on Engineering Management, 2012.
- [3] Haghirian, P., Madlberger, M., and Tanuskova, A., “Increasing Advertising Value of Mobile Marketing – An Empirical Study of Antecedents”, Proceedings of the 38th Annual Hawaii International Conference on System Sciences, 2005.
- [4] Gao, J.Z., and Ji, A., “SmartMobile-AD: An Intelligent Mobile Advertising System”, The 3rd International Conference on Grid and Pervasive Computing Workshops, 2008.
- [5] Nigel Davis, Marc Langheinrich, Rui José, and Albrecht Schmidt, “Open Display Networks: A Communications Medium for the 21st Century,” IEEE Computer Society, 2012, pp.58
- [6] Scheible, J. and Ojala, T., “MobiSpray: mobile phone as virtual spray can for painting BIG anytime anywhere on anything”, SIGGRAPH 2009 Art Gallery, 2009.
- [7] J. Hong et al., “Context-aware System for Proactive Personalized Service Based on Context History”, Expert Systems with Applications, vol.36, 2009, pp. 7448-7457
- [8] J.Müller et al., “Display Blindness: The Effect of Expectations on Attention towards Digital Signage”, Proc. 7th Int'l Conf. Pervasive Computing (Pervasive 09), LNCS 5538, Springer, 2009, pp. 1-8
- [9] Strohbach, M. and Martin, M., “Toward a Platform for Pervasive Display Applications

- in Retail Environments”, IEEE Pervasive Computing, vol. 10, 2011, pp.19-27
- [10] E. K. Strong, “The psychology of selling and advertising,” New York: McGraw-Hill, 1925.
- [11] Strong, E.K. "Theories of Selling" Journal of Applied Psychology 9, 1925, pp. 75-86
- [12] dentsu Inc., 商標登録番号第 4874525 号, 2005.
- [13] Nigel Davis, Marc Langheinrich, Rui José, and Albrecht Schmidt, “Open Display Networks: A Communications Medium for the 21st Century,” IEEE Computer Society, 2012, pp.58
- [14] J.Müller, A. Schlottmann, and A. Krüger, “Self-Optimizing Digital Signage Advertising,” Adjunct Proceedings of Ubicomp, 2007.
- [15] Erwin Ephron, “Recency Planning”, Journal of Advertising Research, 1997.
- [16] Ioannides AA, Liu L, Theofilou D, Dammers J, et al., “Real time processing of affective and cognitive stimuli in the human brain extracted from MEG signals”, Brain Top 2000; 13: pp.11-19, 2000.
- [17] Astolfi L, De Vico Fallani F, Salinari S, et al., “Brain activity related to the memorization of TV commercials,” I J Bem 2008, 10(1), pp. 1-10, 2008.
- [18] Astolfi L., De Vico Fallani F., Cincotti F., Mattia D., Bianchi L., Marciari M.G., Salinari S., Colosimo A., Tocci A., Soranzo R., and Babiloni F., “Neural Basis for Brain Responses to TV Commercials: A High-Resolution EEG Study”, IEEE Transactions on Neural Systems and Rehabilitation Engineering, Vol. 16, No.6, December. 2008.
- [19] Farid Esfahani, Mohammad Ali Sardar and Behzad Hassannezhad Kashani “Relationship Between Media Advertisements and Purchase of Losing Weight Sport Products in Iran”, World Applied Sciences Journal 17 (7), IDOSI Publications, 2012.
- [20] Wan, A., Rigumye, A., and Jones, P., “Profile Based Routing and Billing Multimedia Content Delivery Network”, International Conference on Networking, International Conference on Systems and International Conference on Mobile Communications and Learning Technologies, 2006.
- [21] Seungjae Shin, Pyung Kim, Yeojeong Yoon, Seongbea Eun, and Hyunsoo Yoon, “Person Wide Web: Active Location based Web Service Architecture using Wireless Infrastructure”, TENCON, 2010.
- [22] Changwoo Yoon, Hoyeon Lee, Seung Hyun Jeon, and Hyunwoo Lee, “Mobile Digital Signage System based on Service Delivery Platform Location based Targeted Advertisement Service”, International Conference on ICT Convergence, 2011.

- [23] A.K. Dey, K. Wac, D. Ferreira, K. Tassini, J.H. Hong, and J. Ramos, “Getting closer: an empirical investigation of the proximity of user to their smart phones,” Proceedings of the 13th international conference on Ubiquitous computing, 2011, pp.163–172
- [24] S. Patel, J. Kientz, G. Hayes, S. Bhat, and G. Abowd, “Farther than you may think: An empirical investigation of the proximity of users to their smartphones,” UbiComp 2006: Ubiquitous Computing, pp.123-140, 2006.
- [25] I. Chronis, A. Madan, and A. S. Pentland, “Socialcircuits: The art of using mobile phones for modeling personal interactions,” Proceedings of the ICMI-MLMI’09 Workshop on Multimodal Sensor-Based System and Mobile Phones for Social Computing, p.1, ACM, 2009.
- [26] MCR2011, ビデオリサーチ, 2011.
- [27] HABIT2010, 博報堂, 2010.
- [28] Yantao Zheng, Lingyu Duan, Qi Tian, and Jin J. S., “TV COMMERCIAL CLASSIFICATION BY USING MULTI-MODAL TEXTUAL INFORMATION”, IEEE International Conference on Multimedia and Expo, July. 2006.
- [29] Bo Wang, Jinqiao Wang, Shi Chen, Ling-Yu Duan, and Hanqing Lu, “Semantic Linking between Video Ads and Web Services with Progressive Search”, IEEE International Conference on Data Mining Workshops, December. 2009.
- [30] 日本民間放送連盟, “メディア接触と消費行動に関する調査”, 2000.
- [31] Iwai, M., Mori, M. and Tokuda, H., “A marketing analysis using massive tiny sensor nodes”, 2009 Sixth International Conference on Network Sensing Systems, September. 2009.
- [32] 清水和人, 木實新一, 岩井将行, 瀬崎薫, “Bluetooth の近接性センサーとしての性能評価,” 信学総大, B-19-7, March. 2012.
- [33] 清水和人, 木實新一, 岩井将行, 瀬崎薫, “Bluetooth による近接性検出タイミングの行動認識を用いた制御手法,” 信学技報, May.2012.
- [34] Kitani, K.M., Okabe, T., Sato, Y., and Sugimoto, A., “Using Individuality to Track Individuals: Clustering Individual Trajectories in Crowds using Local Appearance and Frequency Trait”, IEEE 12th International Conference on Computer Vision, 2009.
- [35] 上田雅夫, “顧客の心理的ハードルを乗り越える”, April.2007.
- [36] Herb Sorensen, “Inside the Mind of the Shopper: The Science of Retailing”, May.2009.
- [37] Hermann Heinrich Gossen, “Die Entwicklung der Gesetze des menschlichen Verkehrs, und der daraus fließenden Regeln für menschliches Handeln”, 1854.

- [38] Kong H. K. Choi, Terry H.S. Chu, and Henry C. B.Chan, “Dynamic and Interactive Intelligent Signage System,” IEEE, 2012.
- [39] ビデオリサーチ, MCR(Media Contact Research)2011, 2011.
- [40] Auditel, Sintesi Mensile 1A, October.2011.
- [41] Sekimoto, Y., Shibasaki, R., Kanaguchi, H. and Shimazaki, Y., “PFlow: Reconstructing People Flow Recycling Large-Scale Social Survey Data”, IEEE Pervasive Computing, 2011.