Vol.2015-UBI-46 No.6
2015/5/11

顧客の身体的属性情報を用いた商品推薦システムのためのスマート買い物カゴの開発

杉本 広大[1,a)]　高瀬 和之[1,b)]　増田 彬[1,c)]　前川 卓也[1,d)]

概要：近年，情報技術の進展により，ロボットやデジタルサイネージを用いたインテリジェントなショッピング支援に関する注目が高まっている．本研究では，買い物カゴに設置した加速度センサを用いて顧客の身体的属性を推定し，その属性に応じた商品を推薦するシステムを提案する．提案システムでは，買い物カゴの持ち手に無線加速度センサノードを設置し，加速度時系列データの収集とデジタルサイネージへの転送を行う．デジタルサイネージでは加速度時系列データから属性推定を行い，顧客属性に応じた推薦品を提示する．これにより，さりげなく顧客属性の推定を行うことができ，顧客の嫌悪感を減らすことが可能となる．また，安価な無線加速度センサノードを用いることで，多人数対応も低導入コストで行うことが可能である．本研究では，無線加速度センサノードを独自に回路基板から設計・実装するとともに，属性推定精度の高い「空の買い物カゴを持って歩行した時の加速度時系列データ」のみを記録するアルゴリズムをセンサノード上に実装し，またそのような加速度時系列データは短時間しか得られないためノイズ影響を受けづらい特徴抽出を行う．実際に取得したデータに対して提案手法を適用し，その推定性能を確認した．

1. 序論

情報技術の進展による国民生活の質の向上は目覚ましく，またその恩恵は多岐に渡る．購買行動もそうした影響を受け大きく形を変えたものの一つであり，インターネットショッピングの拡大に伴い，多様で小規模な商品需要への対応が容易になり，幅広い商品がいつでもどこでも購入できるようになった．また，購買履歴が電子化されたことでマーケットバスケット分析も容易になり，それにより売り上げのみならず，顧客の利便性や満足度も大きく向上させることが可能となった．インターネットショッピングの実店舗販売への優位性の一つに，そうした分析結果をフィードバックしやすいという点が挙げられる．多くのネットショップでは商品の紹介ページに，「その商品を購入した人が，他にどんな商品を買っているか」であったり，「購買履歴や商品閲覧履歴から推測した，その人にオススメできる商品」といった情報を掲載している．

こうしたレコメンデーションの枠組みを実店舗販売にも取り入れるべく，ロボットやデジタルサイネージを用いたインテリジェントなショッピング支援に関する注目が高まっている．従来の「通りかかった人の呼び込みを自動で行う」といった単純なシステムに代わって，「顧客属性を判断しそれに応じた推薦を行う」ような高度なシステムの実現が望まれている．顧客の属性や嗜好に関する購買支援や分析を行うシステムとして，「1) カメラを用いた顔特徴の認識により顧客属性の推定を行い，それに応じた商品を推薦するシステム」[1] や，「2) 商品に付加した電子タグを用いて商品を手に取る行動をモニタリングし，それに合わせて商品情報を提供するシステム」[2] などが存在するが，1) のシステムには，撮影される嫌悪感への懸念や多人数対応にはカメラの設置に工夫が必要という問題点があり，2) のシステムには，商品全てに電子タグを付加しなければならないという，導入コスト・維持コストの問題点がある．

そこで本研究では，既存のシステムで問題であった「嫌悪感への懸念，多人数対応のしづらさ，導入コストの高さ」を解消するため，買い物カゴに設置した安価な加速度センサを用いて顧客の身体的属性を推定し，その属性に応じた商品を推薦するシステムを提案する．無線加速度センサノードを独自に回路基板から設計・実装するとともに，属性推定精度の高い「空の買い物カゴを持って歩行した時の加速度時系列データ」のみを記録するアルゴリズムをセン

1 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University
a) sugimoto.kodai@ist.osaka-u.ac.jp
b) takase.kazuyuki@ist.osaka-u.ac.jp
c) masuda.akira@ist.osaka-u.ac.jp
d) maekawa@ist.osaka-u.ac.jp

ⓒ 2015 Information Processing Society of Japan

サノード上に実装する．またそのような加速度時系列データは短時間しか得られないため，ノイズ影響を受けづらい特徴抽出を行うことにより身体属性推定を行う手法を提案する．

2. 関連研究

近年情報技術の進展により，インテリジェントなショッピング支援に関する注目が高まっており，そうした研究やシステムの開発が積極的に行われている．例えば，2010 年から，マーケティング頭脳を搭載した次世代自動販売機と謳い，JR 東日本ウォータービジネスによる実証実験が行われている [1]．このシステムでは，自動販売機上部に装着したカメラを用いて顧客属性 (年代・性別) を判定し，それに応じたお勧め商品を提示する．こうして得られた顧客属性は POS 情報に付加され，マーケティングにも役立てられている．また季節，時間帯，環境といった要素も加味し商品訴求を行うことで，さらなる顧客の需要喚起を試みている．

インタラクションを高めることで，売上増加や売上操作を図ることを検証した研究も存在する．船谷ら [3] は，実店舗顧客の嗜好をリアルタイムに推定する「商品棚用タブレットコミュニケーションサイネージ - カオミナサイネージ」を開発した．このシステムは顧客の顔の動きをリアルタイムで解析し，選ばれるであろう商品を高い精度で予測する．これにより広告主は，顧客が商品を手に取る前に，顧客の嗜好に基づいた広告を打つ事が可能になるとしている．また顧客にとってこれまでにない新しい購買体験を提供することになり，購買意欲が高まると考えている．実証実験では，「予測と異なる商品を推薦する」という戦略を行い，売り上げを 90%増加させることに成功している．

顧客の購買行動に注目した購買分析を行う研究やシステムも多数存在する．例えば，藤野ら [4] は POS データと RFID を用いた店舗内実験データをもとに，実際に店舗に来店した顧客の店舗内での行動分析を行った．結果としては，実験を行った島根県のスーパーマーケットでは，顧客の動線長と滞在時間には強い相関が見られたが，顧客の動線長と購買点数，滞在時間と購買点数については，強い相関が見られなかった．その結果より，従来の顧客の動線長が伸びると目視する商品が増え購買点数が増加するという顧客行動モデルだけではなく，顧客の動線長や購買点数に影響をするほかの要因を含めたより詳細な顧客行動モデルが必要であると考えている．また，そのほかの原因の可能性として考えられる顧客のセグメント化がなされていない問題についても，顧客のセグメント分けを行い，顧客セグメントごとの顧客モデルを構築することでさらなる詳細な顧客モデルの設計に繋げるとしている．顧客を分ける項目としては，年齢や性別のほか，購買している商品や来店の時間帯などを考え，そのような分類項目による顧客行動の分析が必要であるとしている．

また，加速度データから身体的属性推定を行う研究も多数行われている．Weiss ら [5] はスマートフォンに内蔵されている加速度センサより取得した歩行時のセンサデータから直接，性別や身長，体重といった基本的な身体的属性情報の推定を試みた．増田ら [6] は「ある身体的特徴が類似しているユーザは，ある行動における加速度データも類似している」という仮定の基に，14 種の行動に対してどの行動が目的の身体的特徴の推定に有用かを学習することで高精度な推定を行う手法を構築した．

3. 提案システム

3.1 システム概要

本研究では，既存のシステムで問題であった「嫌悪感への懸念，多人数対応のしづらさ，導入コストの高さ」を解消するため，買い物カゴに設置した安価な加速度センサを用いて顧客の身体的属性を推定し，その属性に応じた商品を推薦するシステムを提案する．システムの完成イメージを図 1 に示す．

本研究では性別・年齢・身長・体重といった商品推薦に有用と考えられる顧客属性を推定することを目指し，以下の手順で推定を行う．

(1) 買い物カゴに取り付けたセンサノードによってある顧客の加速度データを取得する．
(2) 得られた加速度データが，顧客の近くにあるデジタルサイネージに無線で送信される．
(3) デジタルサイネージ上で，送信されたセンサデータを分析することで顧客の身体的属性を推定する．
(4) デジタルサイネージは推定された身体的属性情報を用いて商品の推薦を行う．

提案するシステムでは，加速度センサを用いることでさりげなく顧客属性の推定を行うことができ，顧客の嫌悪感を減らすことが可能となる．また，安価な無線加速度センサノードを使用することで，多人数対応も低導入コストで行うことが可能である．

3.2 法的基準への対応に関する考察

近年，計算機性能の向上にともなってビッグデータの解析が容易になり，従来は特定個人を識別するに至らなかっ

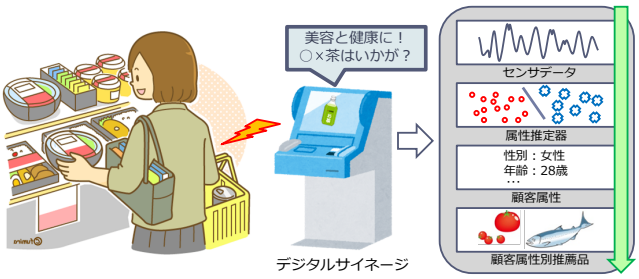

図 1 買い物カゴに設置した加速度センサを用いた商品推薦システム

た情報が，個人を識別するに至っている現状がある [7]．そのため，従来の個人情報保護法の枠組みだけでは，こうした現状に対応することが難しくなっている．そうした時代の流れを受けて，2010 年から総務省においてセンサデータやビッグデータの取り扱いに関する提言が行われているが [8]，法整備は追いついていないのが現状である．しかしながら，将来を見据えてセンサデータの安全な利活用を実現するプライバシー保護技術に関する研究も行われている [9]．本節では，現行法の範囲で提案システムに抵触すると考えられる事項について述べ，その対応案について論じる．

- **プライバシーの権利**
  本システムでは顧客の加速度時系列データの収集を行うため，このセンサデータが個人性を含むかということが焦点となる．加速度時系列データを用いた個人認証に関する研究も行われているため [10]，著者はこれを個人性を含むものと考えている．そのため，顧客が拒否するのであれば、センサデータの収集はされないべきであると考える．簡単な対応策としては「センサノードの装着されていない買い物カゴも併せて用意する」という方法が考えられる．また，顧客の同意を経て収集された情報であっても，後からユーザの申し出があった場合削除できるようにするべきである．これについては，デジタルサイネージで属性推定を行った後，使用したセンサデータを即座に削除することで，自然と対応が可能である．
- **通信の秘匿性に関する保障**
  本システムでは無線通信を用いて加速度時系列データの送受信を行うため，データの盗聴・改ざんが第 3 者によって行われないようにしなければならない．今回，消費電力の観点から Bluetooth モジュールを用いて通信を行うが，通信の仕様上，アドバタイジングパケットはいかなる端末からも検知可能なため [11]，第 3 者によって通信の横取りができてしまうという問題がある．そこで，シェイクハンドの際にワンタイムトークンによる認証を行うような実装をする必要があると考える．無線加速度センサノードの計算性能は低くなると見込まれるが，軽量暗号の実装を用いて，実装することは可能であると考える [12]．なお，通信自体は 128bit の AES 暗号により暗号化され，かつアドホック通信が行われるため，通信確立後の盗聴の懸念は少ない．
- **分析内容の正確性に対する責任**
  本システムは一種の情報分析システムに該当するため，データの分析結果が不正確だったことによって起こる損害について、責任を持たなければならない．今回の目的であれば，顧客属性の誤推定結果に基づいた推薦による，顧客の不快感等が該当すると考えられる．対策としては，正確な推定が行えそうにない加速度時系列データを，属性推定の段階でフィルタリングすることが考えられる．簡単な実装としては，顧客同士の特徴ベクトル間のユークリッド距離を顧客非類似度として，全てのトレーニングデータとの非類似度を計算し，その中から 1 番小さな値を検索して，それがある閾値以上なら正確な推定を行えないと判断して，精度の高い推薦のみを行う等の実装が考えられる．

3.3 無線加速度センサノードの構成

3.3.1 買い物カゴに設置するハードウェア構成

[回路構成]

本研究では，独自に回路基板から無線加速度センサノードの開発を行った．開発費用は 1 台あたり約 5,000 円である．実際に開発した無線加速度センサノードの写真を図 2 に示す．ここでは選択した電子部品と，それらの特性の簡単な説明を行う．

(1) **プロセッサ:**
プロセッサには，Atmel 社の Atmega328p を用いた．このプロセッサは非常に低消費電力であり，また細かく ADC や通信インターフェイスの電力供給を切り替えることが可能である．今回，クロックソースとして 12MHz のセラロックを選択し，併せて用いた．

(2) **加速度センサ：**
加速度センサには，Kionix 社の KXR94-2050 を用いた．このセンサは 3 軸に ±2G の出力レンジを持ち，アナログ値を出力する．RC ローパスフィルタを適宜設計することで，最大 800Hz までの帯域幅を有する．

(3) **無線通信モジュール：**
無線通信モジュールには，connectBlue 社の OLS425 を用いた．このモジュールは第 4 世代 Bluetooth 規格の一部である Bluetooth Low Energy に対応し，非常に低消費電力で動作する．マイコンのシリアルインターフェイスとこのモジュールを接続し，データの送受信を行った．

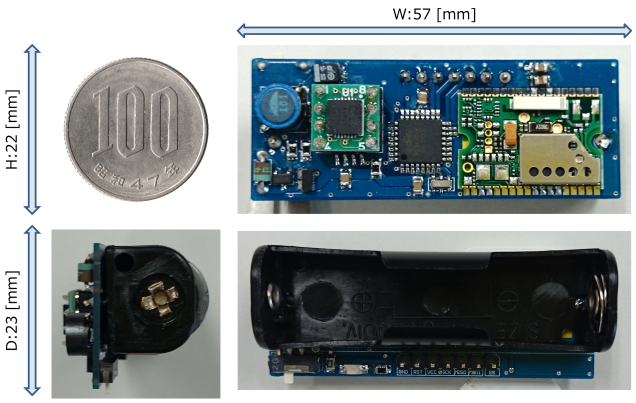

図 2 開発した無線加速度センサノード

購買ステップ	待機中	購買開始	歩行中	静止中	商品追加	それ以降
時系列						
データ保持	No	No	Yes	No	No	×
電力供給	Acc：ON BLE：OFF	Acc：ON BLE：OFF	Acc：ON BLE：OFF	Acc：ON BLE：OFF	Acc：ON BLE：OFF	Acc：OFF BLE：ON
重力軸	x軸	z軸	×	×	×	×
$Var[\lvert\vec{a}\rvert]$	×	×	大きい	小さい	特大	×
平均への交差数	×	×	2	1〜4	10〜	×

図 3　各購買ステップにおける処理の概要

(4) **電源 IC：**

電源 IC には，Holtek Semiconductor 社の HT7733A を用いた．この IC は 0.7V からの電圧を 3.3V まで昇圧することが可能である．これと併せて，バッテリーとして Panasonic 社の eneloop pro 単 3 型を選択し，併せて電源回路として用いた．

[性能評価]

ここでは，開発した無線加速度センサノードの性能限界における理論駆動時間について論じる．理論駆動時間の導出にあたって，設定した条件は以下の通りである．

(1) 通信は確立済みで，常に通信速度の限界で 1byte のランダムな値を送信している．
(2) インジケータ LED を除いた各種センサやモジュールに常に電力供給を行っている．
(3) バッテリーの終端電圧は考慮せず，全ての電力を供給できるものとする．

こうした状況における消費電流を事前に計測した結果，ピーク値が 13.8mA であった．バッテリーの定格容量 2450mAh と定格電圧 1.2V，および電源 IC の入力電圧 1.2V・出力電流 15mA における電力効率 82%と定格出力電圧 3.3V を用いて，$2450[\mathrm{mAh}]\times1.2[\mathrm{V}]\times0.82/(3.3[\mathrm{V}]\times13.8[\mathrm{mA}])\cong53[\mathrm{h}]$ が理論駆動時間となる．

3.3.2　ソフトウェア構成

無線加速度センサノードでは，ノイズが重畳せず，属性推定精度の高いと考えられる「空の買い物カゴを持って歩行した時の加速度時系列データ」のみを記録する．そのために，購買開始から最初に商品が追加されるまでを適切に検知し，その中から歩行中の加速度時系列データのみを記録するアルゴリズムを実装した．各購買ステップにおける処理の概要を図 3 に示す．また，サンプリングレートは 128Hz とした．

64 サンプル (0.5 秒) を 1 フレームとして，各フレームにおいて重力軸の判定や，分散と平均への交差数 (平均に対して時系列が上から下に横切る回数) に対して閾値判定を行うことで，各購買ステップを適切に分解する．具体的には，購買の開始は買い物カゴの持ち手が購買開始時に回転し，それによりセンサノードの重力軸が x 軸から z 軸に変化することを利用して検出をおこなう．そして，分散が 1500 以上かつ，平均への交差数が 3 以下の時に，歩行状態であると判別する．分散が 10000 以上かつ，平均への交差数が 9 以上の時に，商品が追加されたと判断する．商品追加以降は Bluetooth モジュールに電力供給を行い，デジタルサイネージとの通信を待機する．また，各種計算は必要な時に必要な分だけ行い，各種デバイスへの電力供給や通信量もその時々に応じて最小限に抑える．待機中から商品追加までの時間 (加速度センサに電力供給が行われている時間) と，それ以外の時間 (Bluetooth モジュールに電力供給が行われている時間) の比が 1:1 という仮定のもとで，理論駆動時間として 304 時間を達成した．これにより，実際に運用する際にメンテナンスコストを大幅に下げることが可能となる．

3.4　身体的属性情報推定のための特徴抽出

特徴抽出を一定区間ごとに行うにあたり，長時間時系列であれば一部区間がノイズの影響を受けていても，全体の特徴量の一部が特異な値を持つだけであるため，特徴抽出に問題が起きづらい．また，確率分布を作成する際もサンプル数が十分にあると考えられるため，そうした観点からもノイズ影響を受けづらい．

しかし，本システムで取得可能な加速度時系列データは短時間となる場合が多く，確率分布の作成は現実的ではない．また，時系列データにノイズが重畳した場合，特徴量の大部分が特異な値となることと等しいため，学習や推定精度に大きく影響が出てしまう．

そこで本研究では，ノイズ影響を受けづらい特徴抽出手法を考察し，それによって推定精度の向上を目指す．本節では，ノイズ影響を信号の時間領域・周波数領域双方から低減させることを目的に，諸々の手法について説明を行う．

ⓒ 2015 Information Processing Society of Japan

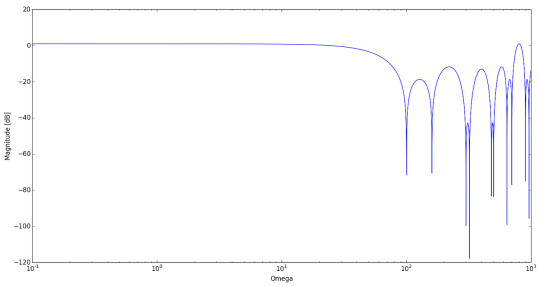

図 4　9 次の移動平均フィルタの周波数特性

3.5　移動平均フィルタの周波数特性

時系列データからノイズを除去する最も簡単な方法は，ローパスフィルタを用いることである．ローパスフィルタの設計には有限インパルス応答 (FIR) を用いるものと，無限インパルス応答を用いるものが存在するが，今回は有限インパルス応答フィルタの代表的なものである，移動平均フィルタを用いた．

入力信号を $x[n]$，出力信号を $y[n]$ としたとき，N 次の移動平均フィルタは式 1 で定義される．

$$y[n] = \frac{1}{N}\sum_{k=-N/2}^{N/2} x[n+k] \tag{1}$$

これを z 変換で書き換え周波数応答を求めると以下のようになる．

$$H(z) = \frac{Y(z)}{X(z)} = \frac{1}{N}\sum_{k=-N/2}^{N/2} z^{-k} \tag{2}$$

$$H(e^{i\omega T}) = \frac{1}{N}\sum_{k=-N/2}^{N/2} e^{-ik\omega T} \tag{3}$$

N を 9，$f_s = \frac{1}{T}$ を 128 とした際の，移動平均フィルタのゲイン特性を図 4 に示す．

有限インパルス応答であることから，出力の安定性が保障される．また，非常に原理が簡単であるため，計算能力の乏しいマイコン上への実装や，FPGA 等のハードウェアでの実装も容易に行えるという利点がある．今回，9 次の移動平均フィルタを前処理として時系列データに適用し，その後各特徴量を求めた．

3.6　線形予測スペクトル包絡

伊藤らの研究により，3 軸加速度センサを用いた歩行状態識別において，音声処理で用いられているケプストラム分析を応用することの有用性が示されている [13]．ケプストラムは歩行時の加速度の平均や分散等の統計量と比較して，経年変化や路面状態変化といった取得環境の影響を受けにくい特徴であることがわかっている．そこで本研究でも，ケプストラム分析に着目し，それにより得られるスペクトル包絡を特徴の 1 つとして用いる．

入力信号を $x(t)$ とした場合，ケプストラム $c(\tau)$ は，波形のスペクトル $|X(\omega)|$ の対数の逆フーリエ変換として定義され，スペクトル包絡と微細構造を近似的に分離して抽出できる特徴がある．スペクトル包絡は，時間波形における大局的な特徴を表し，微細構造は，時間波形における基本周期を表す．

時間波形 $x(t)$ を，2 つの信号 $g(t)$ と $h(t)$ で表すことを考える．ただし，$g(t)$ は周期信号であり，$h(t)$ はインパルス応答である．$x(t)$ はこれら 2 つの信号の畳み込みとして次のように与えられる．本研究では，加速度センサから取得した離散時系列データのため，入力信号は式 5 のように表される．

$$x(t) = \int_0^t g(\tau)h(t-\tau)d\tau \tag{4}$$

$$x[n] = \sum_{k=-\infty}^{\infty} g[k]h[n-k] \tag{5}$$

$$X(\omega) = G(\omega)H(\omega) \tag{6}$$

ただし，$X(\omega)$，$G(\omega)$ および $H(\omega)$ はそれぞれ，$x[n]$，$g[n]$，および $h[n]$ のフーリエ変換である．

$g[n]$ が周期関数の場合には，$|X(\omega)|$ はその周期の逆数の周波数ごとの線スペクトルとなる．よって，入力信号の波形の一部を切り出してその標本値系列をフーリエ変換して求めた $|X(\omega)|$ は，周波数軸上に等間隔の鋭いピークを持つ．その対数 $\log|X(\omega)|$ を求めると，

$$\log|X(\omega)| = \log|G(\omega)| + \log|H(\omega)| \tag{7}$$

となる．次に，式に対して周波数 ω を変数としてフーリエ逆変換する．これがケプストラムであり，フーリエ変換を $\mathscr{F}$ の記号で表すと．

$$\begin{aligned} c(\tau) &= \mathscr{F}^{-1}\log|X(\omega)| \\ &= \mathscr{F}^{-1}\log|G(\omega)| + \mathscr{F}^{-1}\log|H(\omega)| \end{aligned} \tag{8}$$

となる．これを次式で示すように，逆離散フーリエ変換 (IDFT) で求める場合は，波形の標本化の場合と同様に折り返しが生じるため，サンプル数 N を大きくとる必要がある．

$$c_n = \frac{1}{N}\sum_{k=0}^{N-1} \log|X(k)|e^{i\frac{2\pi}{N}kn} \tag{9}$$

式 7 の右辺第一項は，スペクトル上の微細構造，すなわち比較的細かい周期パターンであり，第 2 項はスペクトル包絡，すなわち周波数による変化のゆるやかなパターンを表す．

ケプストラム分析には複数の手法が存在するが，今回線形予測ケプストラム分析を用いた．まず，線形予測分析 (LPC) は，離散時間系において，ある時点の値がそれ以前の値の線形結合で表現できるという仮定に基づき波形を予

測するものである．時間離散的信号 x_t において，現時点の標本値 x_t と，これに隣接する過去の p 個の標本値との間の線形予測値を $\hat{x}_t$ とすると，$\hat{x}_t$ は次のように表される．

$$\hat{x}_t = \alpha_1 x_{t-1} + \alpha_2 x_{t-2} + \cdots + \alpha_p x_{t-p} \tag{10}$$

線形予測係数 α は標本値 x_t と線形予測値 $\hat{x}_t$ の間の誤差が最小となるように定める．この LPC で求めた線形予測係数を次式に代入する．

$$H(z) = \frac{1}{1 + \sum_{i=1}^{p} \alpha_i z^{-i}} = \frac{1}{A(z)} \tag{11}$$

線形予測ケプストラム分析では式を信号のスペクトル密度とみなし，

$$X(\omega) = H(z)|_{z=e^{i\omega t}} \tag{12}$$

とおいたときのケプストラムを算出する．

線形予測ケプストラム分析では，線形予測分析による線形波形モデルに対してケプストラム分析を行うため，元の波形に対するケプストラム分析よりも，スペクトルのピーク特性が抽出しやすいという利点がある．本研究では，特徴量の 1 つとして，このケプストラム係数を高速解法である Levinson-Durbin Algorithm[14] を用いて算出し用いる．

3.7 代表特徴ベクトル選択

本研究では，得られた加速度時系列データに対して，スライディングウィンドウ毎に特徴量の算出を行う．こうしていくつかの特徴ベクトルが得られるので，この中から代表となる特徴ベクトルを抽出する必要がある．k 近傍法を用いる方法や，ベクトル符号化をもとにコードブックを作成する方法などが考えられるが，今回は得られた特徴ベクトルの平均を代表特徴ベクトルとする方法を用いる．

4. 評価実験

4.1 購買ステップ判定

4.1.1 購買開始判定

カゴを持ち上げた際にインジケータ LED を点灯するファームウェアを実装し，評価実験を行った．静止状態からカゴを持ち上げる動作を 50 回行い，インジケータ LED が点灯するかを確認したところ，50 回全てのケースでインジケータ LED の点灯を確認できた．すなわち，正解率 100%で購買の開始を検出できた．

4.1.2 歩行状態判別

歩行状態かそうでないかを加速度時系列データとともに記録するファームウェアを実装し，評価実験を行った．歩行状態と静止状態を 4 秒ごとに繰り返す 24 秒間程度の動作を 10 セット行い，人手でそのデータの確認を行った．その結果，静止状態を歩行状態と誤判別することはなかったが，歩行状態を静止状態と判別することが 5%の割合で存在した．すなわち，正解率 95%で歩行状態を判別できた．

4.1.3 商品追加判定

商品が追加された際にインジケータ LED を点灯するファームウェアを実装し，評価実験を行った．50g，100g，500g，1kg，2kg の物体についてそれぞれ 10 回ずつ買い物カゴへの投入を試みた．その結果，50g の物体については 6 回インジケータ LED の点灯を確認できなかったが，それ以外の全ての物体について，投入時にインジケータ LED の点灯を確認できた．これより，正解率 84%で商品の追加を判定できた．

4.2 身体的属性情報推定

4.2.1 実験環境

10 代から 80 代の男女，計 114 名について，空のカゴを持って歩行した時の加速度時系列データを収集し，その中から性別と年齢が偏らないように 98 名をランダムに抽出し，実験データとして用いた．性別と年齢の分布を図 5 に，身長の分布を図 6 に，体重の分布を図 7 にそれぞれ示す．

また，加速度センサノードは買い物カゴの持ち手を紐でしっかりと固定し，握り手のズレによる個人差が出ないようにした．正確な加速度時系列データを収集するために，SD カードに記録を行うセンサノードを新たに作成し，256Hz のサンプリングレートで 3 軸の加速度を測定した．実際に作成した加速度センサノードの写真を図 8 に示す．

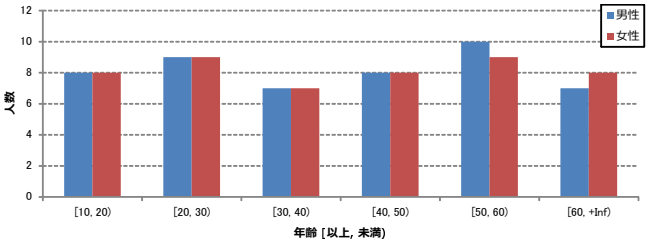

図 5 抽出した実験協力者の性別・年齢分布

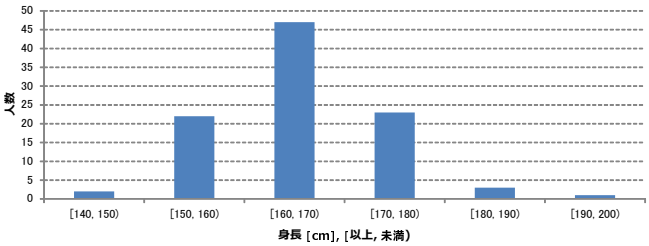

図 6 抽出した実験協力者の身長分布

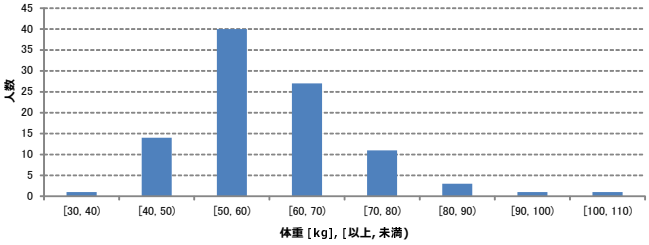

図 7 抽出した実験協力者の体重分布

表 1　各推定における分類器・設定パラメータ

年齢	性別	身長	体重
Support Vector Classifier 構成：One vs Rest カーネル関数：ガウシアンカーネル C パラメータ = 50 γ パラメータ = 0	Support Vector Classifier カーネル関数：リニアカーネル C パラメータ = 0.025	k-Nearest Neigbor Regressor k パラメータ = 5 重みづけ：距離に応じた重み	k-Nearest Neigbor Regressor k パラメータ = 8 重みづけ：距離に応じた重み

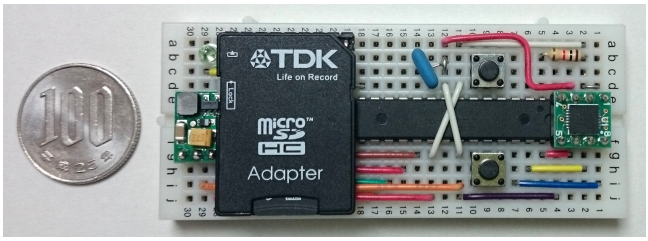

図 8　SD カードに記録を行う加速度センサノード

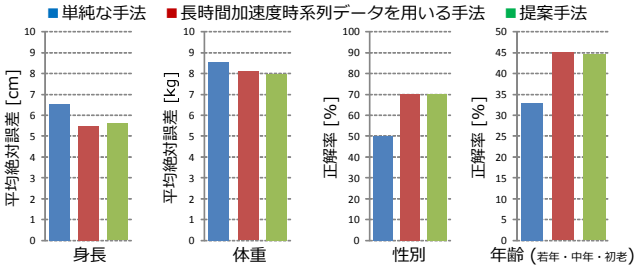

図 9　実験結果

加速度センサノードの設置位置は実際のシステム利用時と同様，買い物カゴの持ち手部分とした．

4.2.2　データ収集時の倫理的配慮

加速度時系列データは個人性を含むものと考えられる [10]．また体重や年齢といった属性情報は，人に知られることに嫌悪感をおぼえる可能性が高い．そこで，実験協力者には研究の目的と実験内容についてレジュメと口頭で説明し，また同意を求めることが強制的にならないように配慮した．加速度時系列データの使用目的および秘密保持についても，併せて平易な言葉で説明を行った．実験協力者の身体的属性情報の収集は Android 端末上で動作するアンケートアプリで行い，回答結果を即座に画面から消去すること，および内部でデータのランダマイズ処理を行うことで，こちらからはその人がどういった身体的属性情報を持つかを知ることができないよう配慮した．

4.2.3　実験結果

今回，性別と年齢の推定には Support Vector Machine を，身長と体重の推定には k-Nearest Neighbor Regressor を用いて，身体的属性情報の推定を行った．また，それぞれグリッドサーチによるパラメータ調整を行った．それぞれの分類器における設定パラメータを表 1 に示す．

特徴量には 3.6 節で論じた線形予測スペクトル包絡を線形予測次数 32 で求めたほかに，基本統計量である最大値，最小値，平均値，標準偏差を計算し，併せて用いた．スライディングウィンドウのサイズは 256 サンプル，スライド幅は 16 サンプルとした．

年齢については若年を 10〜20 代，中年を 30〜40 代，初老を 50〜60 代とする，3 クラス分類を行った．また，Support Vector Machine へ適用する特徴ベクトルについては，各特徴量を平均 0，分散 1 となるよう，規格化して用いた．k-Nearest Neighbor Regressor へ適用する特徴ベクトルについては，主成分分析により 32 次元まで次元削減を行い，特徴量の相関関係 (多重共線性) による推定への影響がでないよう考慮した．

提案手法を「■ 4 秒間の加速度時系列データを用いる手法」とし，比較手法として「■性別と年齢はランダムに選択した値を，身長と体重は平均値を推定結果とする手法」，および「■ 8 秒間の加速度時系列データを用いる手法」を用意した．これらの手法に対して，Leave-one-user-out 交差検定を行った．その実験結果を図 9 に示す．

4.3　考察

今回，身長や体重の推定結果は単純な手法より精度が悪くなることはなかったものの，高い精度を出せたとは言えない結果になった．これは，身長と体重はある程度統計的に正確な分布を仮定することができるにもかかわらず [15]，そのあたりを加味していないことも原因の 1 つだと考える．

一方，性別に関しては，70%程度の高い推定精度を行うことができた．買い物カゴを把持した際の歩行には大きな性差が存在すると考える．

また，年齢については非常に精度が悪く，現実的なアプリケーションとしての利用に足る水準には到達できていない．これについては，加速度センサ以外のセンサも利用して，精度を改善する必要があると考える．

また今回は特徴量の寄与度合について検証を行えなかったが，これについても事前に特徴量の重要度を学習するような手法 [16] や，クラスの多峰構造を加味する，半教師ありの次元削減法 [17] 等を用いることで，推定精度の改善が可能と考える．

5.　結論

本研究では，低導入コスト・多人数対応・低嫌悪感でインテリジェントなショッピング支援を実現することを目的

として，無線加速度センサノードの開発および，短時間加速度時系列データからの身体的属性情報の推定手法について検討を行った．

提案デバイスを用いることで，属性推定に有用な「空のカゴを持って歩行した時の加速度時系列データ」のみを精度良く収集することに成功した．

また，10 代〜80 代の男女，計 114 名について加速度時系列データの収集を行い，性別・年齢・身長・体重といった 4 つの身体的属性について機械学習による推定を行った．Leave-one-user-out 交差検定の結果では，全ての属性について，提案手法で単純な手法の精度を下回らず，また長時間加速度時系列データを用いる手法と同程度に，推定が行えることを示した．

今後の課題として，よりセンサノードの消費電力を抑え駆動時間を延ばすことや，加速度センサ以外のセンサから収集される時系列データを用いることで，身体的属性情報の推定精度向上を目指したい．具体的には，クロック供給元をソフトウェアで選択できるマイコンを使用することで消費電力を抑え，脈拍等の年齢に相関の高いデータを取得するセンサを組み込むことによる根本的な精度改善を考える．身体的属性情報の推定手法に関しても，ノイズ影響低減のような基礎的なアプローチだけでなく，本研究室で行われた先行研究で有用性が示唆されている，特徴ベクトルの類似するユーザの属性を用いて，補正を行うような手法を考え [6]，推定精度向上を目指したい．

謝辞　本研究の一部は，公益財団法人 国際科学技術財団 2014 年度研究助成の支援により行われた．

参考文献

[1] 株式会社 JR 東日本ウォータービジネス，“次世代自動販売機 - エキナカ自販機 acure ＜アキュア＞，” http://www.acure-fun.net/.
[2] METRO Group RFID Innovation Center, “Informations- und entwicklungsplattform fr die zukunft des handels,” , 2007.
[3] 柴田智広，船谷浩之，“顔向きに基づいたリアルタイムでの顧客嗜好予測方法について，” Technical report，九州工業大学 大学院生命体工学研究科，2014.
[4] 藤野俊樹，北澤正樹，山田隆志，高橋雅和，山本学，吉川厚，寺野隆雄，“実データに基づく小売店舗内における顧客行動の分析，” 第 4 回社会システム部会研究会，2013.
[5] G.M. Weiss, and J.W. Lockhart, “Identifying user traits by mining smart phone accelerometer data,” Fifth International Workshop on Knowledge Discovery from Sensor Data, pp.61-69, 2011.
[6] 増田彬，前川卓也，“身体に装着した加速度センサを用いた身体的特徴情報推定手法の提案，” 電気学会 情報システム研究会，Is-13-027，pp.29-32，2013.
[7] 総務省，ビッグデータの活用の在り方について，，2012.
[8] 総務省，利用者視点を踏まえた ICT サービスに係る諸問題に関する研究会 - 第二次提言，，2010.
[9] 伊豆哲也，伊藤孝一，津田宏，阿比留健一，小倉孝夫，“センサーデータの安全な利活用を実現するプライバシー保護技術，” Technical report，富士通株式会社，2013.
[10] 笠原弘樹，“携帯端末の加速度センサを用いた歩行認証に関する研究，” 修士論文，早稲田大学 理工学術院 基幹理工学研究科，2013.
[11] Joe Decuir, Changing the way the world connects - Bluetooth 4.0: Low Energy, , 2010.
[12] K. Papagiannopoulos, and A. Verstegen, Speed and Size-Optimized Implementations of the PRESENT Cipher for Tiny AVR Devices, , 2013.
[13] 智則伊藤，聡介上原，弘樹笠原，将嗣市野，英樹吉井，和宏鶴丸，二郎甲藤，尚久小松，“加速度センサを用いた歩行状態識別におけるケプストラム分析の有効性に関する一考察 (ライフログ, ライフログ活用技術, オフィス情報システム, 情報通信マネジメント, 一般)，” 電子情報通信学会技術研究報告. LOIS, ライフインテリジェンスとオフィス情報システム，vol.111，no.383，pp.39-44，jan 2012.
[14] C. Collomb, “Linear prediction and levinson-durbin algorithm,” Technical report, 2009.
[15] 佐藤勇太，“身長と体重における統計的分布の特性，” 修士論文，中央大学 大学院理工学研究科，2012.
[16] M. Gonen，E. Alpayd in，“Multiple kernel learning algorithms，” J. Mach. Learn. Res.，vol.12，pp.2211–2268，July 2011.
[17] M. Sugiyama, T. Idé, S. Nakajima, and J. Sese, “Semi-supervised local fisher discriminant analysis for dimensionality reduction,” Machine learning, vol.78, no.1-2, pp.35–61, 2010.

ⓒ 2015 Information Processing Society of Japan