

# モバイルコンピューティングによる エモーショナル・イーティングの検知

栄元 優作<sup>1,a)</sup> 佐々木 航<sup>1,b)</sup> 西山 勇毅<sup>3,c)</sup> 大越 匡<sup>1,d)</sup> 中澤 仁<sup>2,e)</sup>

**概要:** ストレスや感情の変化に左右された食行動はエモーショナル・イーティングと呼ばれる。エモーショナル・イーティングが発生する原因として、ストレスや生活習慣の乱れによる自律神経やホルモンバランスの乱れがあげられる。したがって、自律神経の活性度やホルモン分泌量を継続して観察・分析することで、エモーショナル・イーティングの発生を予測することが可能である。しかし、それらの計測には特殊な生体センサが必要であり、また長時間の使用は負担が大きい。本研究では、ユーザが日常的に利用しており、かつ利用者の行動パターンの特徴が表れるスマートフォンのセンサ情報と機械学習を組み合わせることで、エモーショナルイーティングの検知に取り組む。そして、スマートフォンのセンサデータと食生活データを収集する SEED システムを構築し、収集データからエモーショナル・イーティングを検知する機械学習モデルを作成した。本システムを用いて 60 人の被験者から 28 日間のデータを収集したところ、87.5%の精度でエモーショナル・イーティングを検知することに成功した。

**キーワード:** 行動推定, エモーショナル・イーティング, 情動的摂食, 機械学習, スマートフォン, モバイルセンシング

## Mobile Computing-based Emotional Eating Detection

### 1. はじめに

近年センサの小型化や低価格化により、様々なセンサが搭載されたモバイル・ウェアラブルデバイスが登場し普及している [1]。これらのセンサデータを収集・解析することでコンピュータが人間の行動や振る舞いを理解できるようになっている [2]。中でも、喫煙や飲酒といった人体に悪影響を及ぼす行動の推定が可能となりつつある [3], [4]、人体に悪影響を及ぼす行動や習慣の一つに、「エモーショナル・イーティング」と呼ばれる、ストレスや感情の変化によってつい何か食べてしまったり、食べすぎてしまう食行

動 [5], [6] が存在する。エモーショナル・イーティングが習慣づくると、必要以上の食物摂取が続き肥満や過体重を招く危険性がある。エモーショナル・イーティングは、自律神経やホルモンバランスの乱れによって発生すると考えるため、これらを継続的に観測・分析することでその発生を推定でき、対策に繋がれると考えられる。しかしながら、自律神経やホルモンバランスの計測には生体センサが必要であり、持続的な計測には利用者への負担が大きく実用コストも高い。そこで本研究では、我々が日常的に利用し、また利用者の行動パターンの特徴 [7], [8] が表れるスマートフォンのセンサ情報と機械学習の技術を組み合わせることで、エモーショナル・イーティングの検知に取り組む。スマートフォン上のセンサデータと日常の食生活データを収集するシステム「SEED」を構築し、収集したデータから、各食事行動がエモーショナル・イーティングがどうかを分類する機械学習モデルを作成した。60 人の被験者に対する 28 日間の評価実験を実施した結果、3 時間ごとのセンサデータで過去 9 時間分のデータを合わせて学習させた際に、87.5%の分類精度が確認される等、当該センサ

<sup>1</sup> 慶應義塾大学大学院政策・メディア研究科  
Graduate School of Media and Governance, Keio University  
<sup>2</sup> 慶應義塾大学環境情報学部  
Faculty of Environmental and Information Studies, Keio University  
<sup>3</sup> 東京大学生産技術研究所  
a) eigen@ht.sfc.keio.ac.jp  
b) wataru@ht.sfc.keio.ac.jp  
c) yuukin@iis.u-tokyo.ac.jp  
d) slash@ht.sfc.keio.ac.jp  
e) jin@ht.sfc.keio.ac.jp

データを用いてエモーショナル・イーティングを検知することにはじめて成功した。

## 2. 感情と食事

### 2.1 食生活とストレス

我々の食生活には様々な事象が関係しており、ストレスは密接な要因の一つである。心理学的観点では、ストレスは「我々の幸福を脅かすような状況や自身で処理できないほどの物事が起こった時」に発生する [9]。したがって、ストレス発生の有無を確認するためには自分の状況を鑑みて主観的に判定する必要がある [10]、また個人差もあるためそれらを考慮して考える必要がある。

Lazarus らは、高レベルのストレスは常に高い負の感情と結びついているため、ストレスは人間の感情と密接に関連していると主張する [11]。またストレスによって様々な種類の身体的、精神的な不調が発生することも確認されており [12]、例として体重、ウエストサイズ、BMI の増加や、長期間での肥満発生があげられる [13], [14]。

またストレスが発生すると、感情認識に関わる脳機能ネットワークが活性化され、グルココルチコイドやインスリンの分泌量が増加する。これらの変化は、(1) 食事の摂取量や (2) 選択、(3) 食べる動機といった我々の食生活に大きな影響を及ぼす [15], [16]。(1) 食事摂取量については、ストレスの原因や質によって食事量が増加もしくは減少することが分かっている [17], [18]。例えば、非常にストレスの高い出来事の後には食事量が減少し、特に家族間におけるストレスは体重減少につながる事が明らかとなっている [19]。(2) 食事の選択については、ストレスの質との関係が明らかとなっている。例えば長期間のストレスでは、エネルギーが多い食品すなわちカロリー価が高いものを積極的に摂取し [15]、一方で主食や野菜の摂取量が低下する [15]。(3) 食べる動機に関しては、ストレスによって、「空腹ではないが何かを食べたい」という欲求を増加させることが明らかとなっている [20]。つまり空腹という生理的欲求を満たすために食事を行うのではなく、「何かを食べたい」「口にしたい」という食べ物を欲する心理的欲求を満たすための食事をとってしまう [21]。

### 2.2 エモーショナル・イーティング

このような「ストレスやその時の感情に駆動される食行動」は「エモーショナル・イーティング (情動的摂食)」 [5], [6] と呼ばれ、現代社会における問題として近年注目されている。

エモーショナル・イーティングの発生原因には自律神経 [22] の乱れが関わっているとされる。自律神経とは様々な内臓器官や特定の動作に関わる神経で、交感神経と副交感神経の二種からなり、人体においてはこの二種がバランスをとりながら動いている [23]。しかし精神的なストレス

や睡眠不足などの生活習慣の悪化によってこのバランスが崩れると、体はバランスを取り戻そうとする。例えば交感神経の方が優位になった場合、体は副交感神経を活性化させるための動作を促す。そのような動作には、リズム運動や入浴、食事などが存在するが、中でも食事は比較的容易に行えるため、習慣的に食事をしていまいがちである。このように、副交感神経の活性化手段としての食事に大きく依存してしまっている状態が、エモーショナル・イーティングと考えられている。したがってエモーショナル・イーティングを検知できれば、食事以外の行動を提供・推薦することで、状況改善を促せると考えられる。

また、特定の脳内物質 (ホルモン) [24] もエモーショナル・イーティングの発生に関係があると示唆されている。

例えば、「幸せホルモン」と呼ばれ、分泌されると幸福感に包まれストレスをやわらげる効果があるセロトニン [25] は、生活習慣が乱れたり生成のための栄養素が足りないと分泌量が低下してしまう。その場合、セロトニンを増加させる身近な方法の一つとして甘いものを食べてしまうようになり、エモーショナル・イーティング発生につながっていると考えられる。

エモーショナル・イーティングはストレス発散の方法の一つとしても認識されているが [26], [27]、食事による発散が習慣化してしまうと、夜食症候群といった摂食障害に陥る危険性がある。夜食症候群は、夕食後に 1 日の摂取カロリーの 25% から 50% 以上の食事を摂取してしまう摂食障害である。また不眠症を合併している可能性が多く、何かを食べないと眠れないと思ってしまう夜中に起きだして食べてしまうこともある。こういった摂食障害が続くと肥満や糖尿病などの生活習慣病を発症する可能性があり、早急な食生活の見直しや改善が求められる。

### 2.3 先行研究と問題提起

このように、エモーショナル・イーティング発生には自律神経のホルモンバランスの乱れが関係することから、これらのデータを継続して測定・分析することで発生を検知・予測できる可能性がある。しかしこれらの生体情報の測定には専用の生体センサや医療資格が必要であり、実施の容易性や継続性において問題がある。

本問題に対し Erin [28] らは、食行動と感情パターンとの関係性、および心拍数や皮膚電位といった測定しやすい生体データによる感情推定モデルの二つを組み合わせることでエモーショナル・イーティングの推定を行った。ラッセルの円環モデル [29] を用いた感情データと食事データを収集し、エモーショナル・イーティングに関係する感情パターンを判別した。さらに、心拍数や皮膚電位を計測する下着型センサを作成し、収集した生体データから円環モデルの 2 軸の値を分類する機械学習モデルを作成した。しかし同研究では、依然として専用の生体センサを搭載したデバイ

スを使用するため実用化コストが大きく、また装着時に被験者がもった違和感によって長時間の使用が困難だったという問題が残る。

そこで本研究では、広く普及し利用者が日常生活において携帯・利用するスマートフォンのみを用いることで利用者の負担を軽減し、エモーショナル・イーティング発生の検知に取り組む。

### 3. SEED システム

本研究では、エモーショナル・イーティングの検知を行うために必要なセンサデータや食事データを収集する Smartphone-based Emotional Eating Detection (SEED) システムを構築した。SEED は利用者が日常的に利用するスマートフォン (iOS) で動作する SEED クライアントアプリケーションと、複数のクライアントからの情報を集約するサーバとで構成される。SEED アプリケーションは利用者の端末に搭載されてるセンサデータを収集し、サーバが収集したデータを保存・分析することでエモーショナル・イーティングの検知を行う。

#### 3.1 スマートフォン上での動作

エモーショナル・イーティングの原因となる自律神経やホルモンバランスの乱れを直接調査するには、心拍センサや脳波センサといった生体センサを常に着用している必要がある。また血液検査の必要もあり、これらのデータを継続して収集することは利用者にとって負担が大きい。さらに、カメラによる撮影は利用者のプライバシーを考慮する必要がある。撮影が可能な場所にも制約が生じる。本研究では、多くの人が日常的に携帯・利用しているスマートフォン上で動作するアプリケーションを実装することで、利用者のセンサデータを収集する。

#### 3.2 センサデータの自動収集

センサデータを用いてエモーショナル・イーティングを検知するには、高品質かつ長期間の持続したセンサデータや食事データの収集が必須である。したがって、利用者が手動でセンサデータを収集・保存することは非常に負担が大きく、アプリケーションの使用率が低下し、高品質で十分な量のデータが集まらずに検知が不十分な結果に陥ってしまうことが危惧される。本アプリケーションでは、センサデータをユーザの操作を必要とせずに自動で収集でき、必要最低限のデータのみ手動で記録もしくは入力してもらうことで利用率の維持に務める。

#### 3.3 エモーショナル・イーティングの検知

エモーショナル・イーティングの発生を検知できるので、発生する前にエモーショナル・イーティングを回避または抑制するサポートや介入をすることが可能になる。エ

モーショナル・イーティングの検知には、1秒間で1件から5件の情報を計測できるスマートフォンのセンサデータを使用しているため、収集データは膨大な数になってしまう。したがって、収集したセンサデータからエモーショナル・イーティングに関連するセンサやその判定をユーザが自身で行うには多大な時間と労力、判定方法に関する知識が要求される。本アプリケーションでは、収集データから機械学習アルゴリズムを用いてコンピュータに学習させることでユーザに判定してもらう必要を無くし、また大量のデータに対し反復的に計算を繰り返すことによって、そこに潜むパターンを見つけ出すことに注力する。

#### 3.4 設計と実装

SEED システムは、センサデータや食事データの収集を行うクライアントアプリケーションと収集したデータを保存し特徴量を抽出、エモーショナル・イーティングの検知を行うサーバとで構成されている。クライアントアプリケーションは iOS9.0 以上の iPhone や iPad で動作する iOS アプリケーションである。図1に SEED システムの構成図を示す。

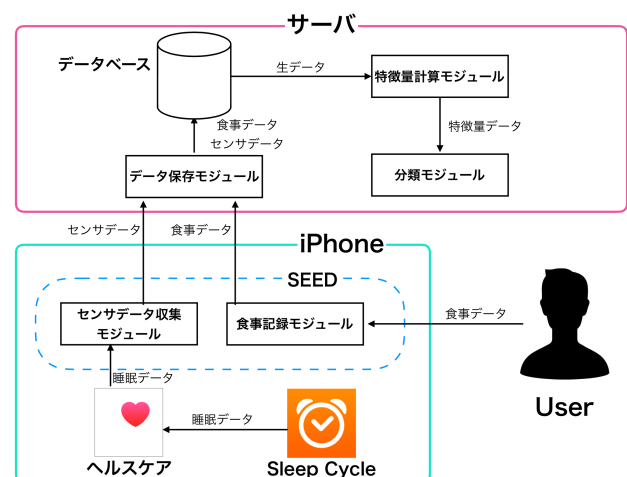


図1 システム構成図

##### 3.4.1 クライアントアプリケーション

クライアントアプリケーションはセンサデータ収集モジュールと食事記録モジュールから構成されている。センサデータ収集モジュールでは、スマートフォンのセンサデータ収集プラットフォームである AWARE[30] を導入し、センサデータを自動で収集する。収集したデータは Wifi に接続している時のみサーバに送信するように実装し、スマートフォンの通信量を使用しないように務めた。

食事記録モジュールでは、普段の食生活のデータや食事前の感情についてユーザに記録してもらう。感情の記録に関しては、Russell が提案した低負荷な感情尺度の一つである円環モデルを採用した [29]。円環モデルでは人の感情を (1) 快と不快、(2) 覚醒と非覚醒の 2 軸で表現した尺度であ

る。図2に、食事前の感情記録画面を示す。利用者には、覚醒-非覚醒という軸と快-不快の軸が交差する交差座標中で、自身の今の精神状態に近い1点を選択してもらう。

感情の記録が終了したら、スマートフォンに標準搭載されているカメラアプリを用いて食事写真を撮影してもらう。撮影した食事の写真と食事の種類(朝食・昼食・夕食・間食)、一緒に食事をした人の人数や金額を記録してもらう。図3に、食事内容の記録画面を示す。本システムでは、食事写真の撮影日時を食事をした時間とし、写真のGPS情報に含まれている緯度経度を食事をした場所のデータとして扱う。

食事内容の記録が終了したら、その時の食事がエモーショナル・イーティングだったかどうかをユーザに回答してもらう。エモーショナル・イーティングにはストレスや感情の変化に起因しており、ストレスや感情を測定するには個人差があるため第三者が客観的に判断することが難しく、対象者の主観的な判断が必要である。したがって、エモーショナル・イーティングかどうかは一様に判断できない可能性が大きいため、ユーザの主観的な判断に基づいて回答してもらう。




図2 食事前の感情記録画面



図3 食事内容記録画面

### 3.4.2 サーバ

サーバは、データ保存モジュールや特徴量計算モジュール、エモーショナル・イーティング検知モジュールから構成されている。データ保存モジュールでは、SEEDアプリケーションが収集したセンサデータや食事データを保存する役割を担っている。センサデータはすべてサーバ内にデータベースに保存をし、食事データも写真を除いて全てデータベースに保存した。

特徴量計算モジュールでは、データベース内に保存されたセンサデータ、食事データ、アノテーションデータを解析できるように特徴量の算出を行う。センサデータは時系列データであり特定の時間帯において重要性が変化する

と考え、各センサデータはそれぞれ決まった時間ごとのフレームに分けて特徴量の計算を行う。フレームの長さは、30分・1時間・2時間・3時間・1日の5種類を用意した。フレームごとに特徴量を算出することで、エモーショナル・イーティングの発生を検知するに必要最低限なデータ量や時間帯を特定することが可能になる。特徴量の算出に関して、加速度や地磁気度などのx,yおよびz成分の3軸データが取得できるセンサに関しては、それらのMagnitudeとして平方和の平方根を算出し、その値をもとに特徴量を算出した。

エモーショナル検知モジュールでは、算出したセンサごとの特徴量データと、記録した食事データをもとにエモーショナル・イーティングの検知を行う。特徴量データはフレームごとに区切られているため、はじめにそれぞれのフレームごとにエモーショナル・イーティングをしたかどうかを表すラベルづけを行う。ラベルは、エモーショナル・イーティングをしたことを表す *Emotional Eating*(EE) と食事はしたがそれがエモーショナル・イーティングではない食事であることを表す *Normal Eating*(NE) の2種類を用意した。食事記録モジュールにおける今の食事がエモーショナル・イーティングだと思いますか?という質問の回答がそう思うの場合に *Emotional Eating* ラベルを、回答がそう思わないの場合は *Normal Eating* ラベルをそれぞれ割り当てた。また、機械学習モデル作成にはデータセットとして単一のフレームのデータを使うのではなく、そのフレームより過去のフレームのデータも合わせた連続したフレームデータを使っている。例えばフレーム長が1時間で過去フレームを3つ使用する場合、任意に時間から直近3時間前までのデータを用いることになる。フレーム数を調整することで、エモーショナル・イーティングを検知するにはどれくらい前のデータが必要になるかがわかり、検知精度の向上に繋がると思われる。

## 4. 評価

SEEDの有効性を明らかにする評価として、スマートフォンのセンサデータのみでのエモーショナル・イーティング検知可能性、およびエモーショナル・イーティングに寄与するセンサ特定の2点を行った。

### 4.1 実験環境

評価実験では、19歳から25歳の大学生および社会人60名(男性37人、女性23人)を被験者とした。被験者は全員、iOS端末を主たるスマートフォンとして日常的に利用している。本実験は、実験前フェーズ、および28日間のデータ収集フェーズから構成される。

### 4.2 実験手順

実験前フェーズでは、被験者に対する内容説明、および



実験参加の同意取得を行った。実験同意書に署名した被験者には、SEED アプリケーション、および睡眠を測定する「Sleep Cycle」[31] アプリケーションを、自身の iOS 端末にインストールしてもらった。

28 日間にわたるデータ収集フェーズでは、以下の 2 つのタスクを実施するよう依頼した。

- (1) アプリケーションのバックグラウンド起動
- (2) 食事の前後における食事データの記録

食事前および食事後の記録に関して、食事を記録する習慣がない被験者は記録を忘れてしまうことが予想されたため、SEED アプリケーションで朝食・昼食・夕食に関して、被験者が好きな時間にローカル通知を出せるように機能を実装した。

### 4.3 評価方法

本評価実験では、データセットの (1) フレーム長、(2) 特徴量として使用するフレーム数、(3) 分類アルゴリズムに関する設定を変化させながら、エモーショナル・イーティング検知モデルの作成を行い、その性能を評価する。

分類アルゴリズムには、Python 言語で書かれた scikit-learn[32] が提供する K-Nearest Neighbor(KN), Decision Tree(DT), Random Forest(RF), AdaBoost(AB), GradientBoosting(GB) の 5 種類を用いた。検知モデルの性能評価にはホールドアウト検証 (size=0.2) を用いて、ラベルづけおよびフレーム処理をしたデータセットをモデルを作る学習データと、モデルを評価するテストデータに分割し評価した。また、学習データを 4 個に分割し、そのうちの  $x$  個をモデルの学習に用いたのち、残りのデータでテストを実施する  $k$ -分割交差検証を実施 ( $k=4$ )、ハイパーパラメータのチューニングなどの学習モデルの最適化を実施した。  $k$ -分割交差検証では、分割された  $x$  個のデータ毎にそれぞれテストを実施し、算出された  $x$  個の評価指標の平均値を評価指標として使用する。したがって、データセットは交差検証用学習データ (60%)、交差検証用テストデータ (20%)、性能評価テストデータ (20%) に分割される。評価指標には、主要な機械学習モデルの評価指標である精度と F 値、適合率、再現率を用いた。

また、エモーショナル・イーティングに寄与するセンサの特定には、scikit-learn[32] が提供する Random Forest を使用した。Random Forest は、決定木をベースとしたアンサンブル分析器で、分類精度に寄与する特徴量の相対的な重要性を計測することができる。Random Forest を用いてこれらのデータからエモーショナル・イーティングを分類するモデルを作成し、重要性が高い特徴量を評価する。

## 5. 結果と考察

本章では、まず実験期間中に収集したデータについて概説し、収集したデータを用いて構築したエモーショナル・

イーティング分類モデルの性能について考察する。

### 5.1 実験結果：データ収集量

図 4 に使用したセンサの一つである位置情報センサの累積データ取得件数を示す。センサデータの累計取得件数は、スムーズな右肩上がりになっており、ほぼ直線に伸びていることがわかる。位置情報センサは 180 秒毎に定期的にデータを収集するため、アプリケーションを常時起動していた場合は一定量ずつセンサデータが取得できる。したがって、実験期間中に大幅に収集量が低下したデータはないことが確認できた。また食事データに関しては、合計で 1458 収集することができた。収集データの内訳としては、*Normal Eating* と判断したデータが 1253 件、*Emotional Eating* と回答したデータが 205 件あった。




図 4 位置情報センサの累積データ取得件数

### 5.2 実験結果：分類性能

表 1 に、アルゴリズムごとの分類性能を示す。作成した分類モデルの精度に着目すると、さまざまなフレーム長やフレーム数において、3 時間ごとの特徴量データを使用してかつ過去 3 フレームのデータも合わせて学習させたモデル (87.5%) が最大の精度を出した (Precision=1.0, Recall=0.2, F1=0.333)。さらに、同モデルはフレーム長が異なる他の分類モデルよりも高い精度になったことが明らかになった。

まず (1) 異なる機械学習アルゴリズム (KN, DT, RF, SV, AG, VG) の観点では、データセットのフレーム長および使用フレーム数が同じ場合、Random Forest が最も高い精度を誇っていることが確認できた。さらに、F 値もおおよそ Random Forest が最大となっていたことが伺えた。したがって、そのときの食事がエモーショナル・イーティングがどうかを分類するにあたって最適なアルゴリズムは Random Forest であることが明らかになった。

次に (2) 特徴量として使用する時系列上の過去フレームの数 (0~3 フレーム) に注目すると、データセットの分類アルゴリズムとフレーム長が同一の場合、使用フレーム数の違いによって精度は変化した。しかし、フレーム数の増減と精度の上昇・減少には大幅に差があり、フレーム数に

合わせて精度が上昇・減少する傾向にあるものや、特に変化しないものがあった。

最後に (3) データセットのフレーム長 (1 日, 3 時間, 2 時間, 1 時間) に注目すると, データセットの分類アルゴリズムと使用フレーム数が同等の場合, フレーム長を拡大・縮小すると精度および F 値が変化したが, どちらの値においても一定の法則性は見られなかった。

本研究の最終的な目標は, 感情的につい何か食べてしまうエモーショナル・イーティングの発生をスマートフォンのセンサデータから検知することで, エモーショナル・イーティングを抑制するために介入やサポートを最適なタイミングで行うことである。具体的なサポート例としては, スマートフォンのプッシュ通知やウェアラブルデバイスを用いて, 任意のメッセージをフィードバックをユーザに届ける。したがって, サポートの効果を増幅させるためにはエモーショナル・イーティングを正しくエモーショナル・イーティングとして検知し, エモーショナル・イーティングでない食事をあやまってエモーショナル・イーティングとして検知されないようにする必要がある。エモーショナル・イーティングを正しくエモーショナル・イーティングとして検知させる場合は, 分類モデルの再現率をできる限り高くする必要があり。一方で, エモーショナル・イーティングではない食事をエモーショナル・イーティングとして誤検知させたくない場合は, 分類モデルの適合率をできる限り高める必要がある。そこで, 作成した分類モデルにおいて再現率と適合率を算出したところ, 再現率の最大値は 1.0 で, その際に適合率は最大で 0.25 であった。また, 適合率の最大値は 1.0 で, その際に再現率は最大で 0.2 であった。

表 1 アルゴリズムごとに精度が最も高かった分類モデルの性能

アルゴリズム	精度	F 値	フレーム長	過去フレーム数
KN	0.825	0.222	2 時間	2
DT	0.810	0.275	1 日	0
RF	0.875	0.333	3 時間	3
AB	0.825	0.222	2 時間	2
GB	0.803	0.315	1 時間	0

### 5.3 実験結果：センサの重要度

本節では, エモーショナル・イーティングの発生と関連のある因子情報を評価する。関連性の評価には, Random Forest を用いて作成した分類モデルから算出できる, 特徴量の重要度を用いる。重要度は, 0 から 1 の値を取り, 1 に近づくほど重要度が高いことを意味する。また重要度は相対的なものであるため, 他の特徴量と比べてどれだけ重要性が高いかを表している。学習モデルは 1 時間毎のデータを Random Forest で学習させたモデル (Accuracy=0.860, F1=0.367) を用いた。同モデルの特徴量を算出した結果,

表 2 降水確率に関する特徴量

(Normal Eating (NE), Emotional Eating (EE))

	ラベル	最大値	最小値	平均値	標準偏差
<i>weather</i>	NE	2.997	0.000	0.045	0.169
<i>_mean_rain</i>	EE	2.997	0.000	0.082	0.350
<i>weather</i>	NE	39.560	0.000	0.722	2.481
<i>_max_rain</i>	EE	8.81	0.000	0.637	1.563

地磁気計や天候, 加速度計の特徴量が高い重要度を示していることがわかった。天候センサに関して, 降雨に関する *weather\_max\_rain* や *weather\_mean\_rain* といった特徴量は重要度が高かった。

表 2 に, 降雨に関する特徴量データを示す。*weather\_max\_rain*, *weather\_mean\_rain* はそれぞれ, 降水確率の最大値および平均値を示している。*weather\_mean\_rain* に注目すると, *Emotional Eating* の方が平均値が高く最大値や最小値は同じだった。*weather\_max\_rain* に注目すると, *Emotional Eating* の方が平均値および最大値が小さくなり, 最小値は同じだった。したがって, 降水確率が高くも低くもない状態だとエモーショナル・イーティングをしてしまいやすいことが伺えた。

また, 食事をした時の時間 (0 時から 24 時) を表す *hour* と, 食事をした日の曜日 (月曜日から日曜日) を表す *day* のデータも重要度が高くなっていることが確認できた。図 5 に時間帯毎のエモーショナル・イーティングの発生件数を示す。昼食の時間帯のピークであると思われる 12 時や, 夕食のピークであると思われる 19 時前後はエモーショナル・イーティングの発生数が多くなっていることがわかる。また, 食事をするには遅い時間帯である 16 時から 17 時の間や, 21 時台はエモーショナル・イーティングの発生割合が高くなっている。

図 6 に曜日ごとのエモーショナル・イーティングの発生件数を示す。曜日に応じたエモーショナル・イーティングの発生件数に大きな変化は見られなかった。しかし, 火曜日や金曜日, 土曜日ではエモーショナル・イーティング発生割合が少し高くなっていることが伺えた。

### 5.4 考察

本評価実験では, 60 人の被験者から 28 日間に渡ってスマートフォンのセンサデータと食事データを収集し, 普通の食事とエモーショナル・イーティングを分類する機械学習モデルを作成した。分類モデルの作成には, 分類アルゴリズムやデータセットのフレーム長, 使用するフレーム数を変更した複数のモデルを作成した。その結果, さまざまなフレーム長やフレーム数において 3 時間毎のデータを過去 3 フレーム使用して Random Forest で学習させたモデルを使用した際に精度は最大の 87.5% に至った。しかし, その際に F 値は 0.333 であることが確認され, 誤検知され




図 5 時間帯毎のエモーショナル・イーティング件数




図 6 曜日毎のエモーショナル・イーティング件数

てしまう可能性があることが確認できた。原因として、使用したデータセットの量の不足や使用したセンサの種類の少なさが挙げられる。同モデルの学習に用いたデータセットは最大で 1000 件程度であり、学習が十分に行えていなかった可能性がある。また、データ収集に関して、合計で 12 種類のセンサを使用した但是这ら以外にもエモーショナル・イーティングに寄与するセンサが存在する可能性がある。そこで、データ収集期間や規模を拡大しより大規模なデータセットを作成することで、より正確に汎化性能を検証することが可能になり、まだ精度の向上も目指せると思われる。

本実験では、エモーショナル・イーティングに寄与するセンサデータを特定するために、作成した学習モデルの特徴量の重要度を算出した。その結果、地磁気計や天候、加速度計といったセンサの特徴量がエモーショナル・イーティングかどうかを分類する際に、重要性が高いことがわかった。天候センサでは、降水確率に関する特徴量の重要度が大きく、降水確率が低くも高くもない状態だとエモーショナル・イーティングをしやすい傾向にあることが見ら

れた。降水確率が低くも高くもない状態として、具体的には雨が降りそうな天候や小雨が降っている状態が該当すると思われる。原因として、そういった状態では雨が降るのか降らないかわからないため、例えば傘を持っていくべきか、外出する時間帯をいつにするかといった懸念を抱いていると思われる。そういった懸念がある状態、すなわち降雨を心配している状態だとストレスが高かったり、気分が下がったりしてエモーショナル・イーティングを引き起こす要素の一つになるのではないと思われる。センサ以外の特徴量として、食事をした時間を表す *hour* と、食事をした曜日を表す *day* についても重要度は高かった。時間に関しては、食事をするには遅い時間帯である 16 時から 17 時の間や、21 時台はエモーショナル・イーティングの発生割合が高くなっている。原因として、食事が遅くなってしまふ場合は、例えば何かの仕事に終わられている時やお昼までの仕事がある時であるため、それらに対するストレスが原因となっていると考えられる。曜日に関しては、火曜日や金曜日、土曜日ではエモーショナル・イーティング発生の割合が少し高くなっていた。原因として、平日の始まりである火曜日や仕事の終わりもしくは休日の始まりである金曜日や土曜日は、仕事のストレスが発生したりもしくはストレスから解放されることが原因となっていると考えられる。

## 6. おわりに

本研究では、ストレスやその時の感情に駆動される食行動である「エモーショナル・イーティング」の回避や抑制を目的とした、エモーショナル・イーティング検知システム「SEED」を構築した。SEED システムは、ユーザが日常的に利用しているスマートフォンからのセンサデータを用いることで、日常生活への容易な適用が難しい生体センサを用いることなく、機械学習アルゴリズムとの協調動作によりエモーショナル・イーティングの検知を行う。

被験者 60 人の 28 日間にわたる評価実験の結果、さまざまなフレーム長やフレーム数においてフレームが 3 時間のデータを、過去 3 フレーム分使用して Random Forest で学習させたモデルを使用した際に精度は最大の 87.5% が確認できた。また、エモーショナル・イーティングの分類精度が最も高かったアルゴリズムは Random Forest であることが判明した。また、地磁気計や天候、加速度計といったセンサの特徴量がエモーショナル・イーティングかどうかを分類する際に、重要性が高いことがわかった。センサ以外の特徴量では食事をした時間帯や曜日のデータも重要度が高いことが確認できた。今後の展望として、ユーザ個人の特徴や個人差を考慮した個人モデルの構築やウェアラブルデバイスなどのデータの使用、そしてエモーショナル・イーティングを抑制するための介入手法の調査及び実装を行う。

参考文献

- [1] 総務省: 平成 27 年度版情報通信白書 (2017).
- [2] Abowd, G. D., Dey, A. K., Brown, P. J., Davies, N., Smith, M. and Steggles, P.: Towards a better understanding of context and context-awareness, *International symposium on handheld and ubiquitous computing*, Springer, pp. 304–307 (1999).
- [3] Bae, S., Ferreira, D., Suffoletto, B., Puyana, J. C., Kurtz, R., Chung, T. and Dey, A. K.: Detecting Drinking Episodes in Young Adults Using Smartphone-based Sensors, *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 1, No. 2, pp. 5:1–5:36 (online), DOI: 10.1145/3090051 (2017).
- [4] Carreiro, S., Fang, H., Zhang, J., Wittbold, K., Weng, S., Mullins, R., Smelson, D. and Boyer, E. W.: iM-Strong: deployment of a biosensor system to detect cocaine use, *Journal of medical systems*, Vol. 39, No. 12, p. 186 (2015).
- [5] Debeuf, T., Verbeken, S., Van Beveren, M.-L., Michels, N. and Braet, C.: Stress and Eating Behavior: A Daily Diary Study in Youngsters, *Frontiers in Psychology*, Vol. 9, p. 2657 (online), DOI: 10.3389/fpsyg.2018.02657 (2018).
- [6] Geliebter, A. and Aversa, A.: Emotional eating in overweight, normal weight, and underweight individuals, *Eating behaviors*, Vol. 3, No. 4, pp. 341–347 (2003).
- [7] Srinivasan, V., Moghaddam, S., Mukherji, A., Rachuri, K. K., Xu, C. and Tapia, E. M.: Mobileminer: Mining your frequent patterns on your phone, *Proceedings of the 2014 ACM international joint conference on pervasive and ubiquitous computing*, ACM, pp. 389–400 (2014).
- [8] Rabbi, M., Aung, M. H., Zhang, M. and Choudhury, T.: MyBehavior: automatic personalized health feedback from user behaviors and preferences using smartphones, *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, ACM, pp. 707–718 (2015).
- [9] Lazarus, R. S. and Folkman, S.: Cognitive theories of stress and the issue of circularity, *Dynamics of stress*, Springer, pp. 63–80 (1986).
- [10] Krohne, H. W.: Stress and coping theories, *International Encyclopedia of the Social Behavioral Sciences*, Vol. 22, pp. 15163–15170 (2002).
- [11] Lazarus, R. S.: From Psychological Stress to the Emotions: A History of Changing Outlooks, *Annual Review of Psychology*, Vol. 44, No. 1, pp. 1–22 (1993).
- [12] Salim, S.: Oxidative stress and psychological disorders, *Current neuropharmacology*, Vol. 12, No. 2, pp. 140–147 (2014).
- [13] Goodman, E. and Whitaker, R.: A Prospective Study of the Role of Depression in the Development and Persistence of Adolescent Obesity, *Pediatrics*, Vol. 110, pp. 497–504 (online), DOI: 10.1542/peds.110.3.497 (2002).
- [14] Koch, F.-S., Sepa, A. and Ludvigsson, J.: Psychological stress and obesity, *The Journal of pediatrics*, Vol. 153, No. 6, pp. 839–844 (2008).
- [15] O'Connor, D. B., Jones, F., Conner, M., McMillan, B. and Ferguson, E.: Effects of daily hassles and eating style on eating behavior., *Health Psychology*, Vol. 27, No. 1S, p. S20 (2008).
- [16] Jastreboff, A. M., Sinha, R., Lacadie, C., Small, D. M., Sherwin, R. S. and Potenza, M. N.: Neural correlates of stress-and food cue-induced food craving in obesity: association with insulin levels, *Diabetes care*, Vol. 36, No. 2, pp. 394–402 (2013).
- [17] Willenbring, M. L., Levine, A. S. and Morley, J. E.: Stress induced eating and food preference in humans: A pilot study, *International Journal of Eating Disorders*, Vol. 5, No. 5, pp. 855–864 (online), DOI: 10.1002/1098-108X(198607)5:5<855::AID-EAT2260050507>3.0.CO;2-O (1986).
- [18] Canetti, L., Bachar, E. and Berry, E.: Food and emotion, *Behavioural processes*, Vol. 60, pp. 157–164 (online), DOI: 10.1016/S0376-6357(02)00082-7 (2002).
- [19] Stenhammar, C., Olsson, G. M., Bahmanyar, S., Hulting, A.-L., Wettergren, B., Edlund, B. and Montgomery, S. M.: Family stress and BMI in young children, *Acta paediatrica*, Vol. 99, No. 8, pp. 1205–1212 (2010).
- [20] De Vriendt, T., Moreno, L. A. and De Henauw, S.: Chronic stress and obesity in adolescents: scientific evidence and methodological issues for epidemiological research, *Nutrition, Metabolism and Cardiovascular Diseases*, Vol. 19, No. 7, pp. 511–519 (2009).
- [21] Reichenberger, J., Richard, A., Smyth, J., Schultchen, D., Pollatos, O. and Blechert, J.: It's craving time: time of day effects on momentary hunger and food craving in daily life, *Nutrition*, Vol. 55-56 (online), DOI: 10.1016/j.nut.2018.03.048 (2018).
- [22] Ekman, P., Levenson, R. W. and Friesen, W. V.: Autonomic nervous system activity distinguishes among emotions, *Science*, Vol. 221, No. 4616, pp. 1208–1210 (1983).
- [23] Brodal, P.: *The central nervous system: structure and function*, Oxford University Press (2004).
- [24] Kolkhof, P. and Baerfacker, L.: 30 YEARS OF THE MINERALOCORTICOID RECEPTOR: Mineralocorticoid receptor antagonists: 60 years of research and development, *Journal of Endocrinology*, Vol. 234, pp. T125–T140 (online), DOI: 10.1530/JOE-16-0600 (2017).
- [25] Mazák, K., Doczy, V. and Kőkösi, J.: Proton Speciation and Microspeciation of Serotonin and 5-Hydroxytryptophan, *Chemistry and biodiversity*, Vol. 6, pp. 578–90 (online), DOI: 10.1002/cbdv.200800087 (2009).
- [26] van Strien, T., Konttinen, H., Homberg, J., Engels, R. and Winkens, L.: Emotional eating as a mediator between depression and weight gain, *Appetite*, Vol. 100 (online), DOI: 10.1016/j.appet.2016.02.034 (2016).
- [27] Michels, N., Sioen, I., Braet, C., Eiben, G., Antje, H., Huybrechts, I., Vanaelst, B., Vyncke, K. and Henauw, S.: Stress, emotional eating behaviour and dietary patterns in children, *Appetite*, Vol. 59, pp. 762–769 (online), DOI: 10.1016/j.appet.2012.08.010 (2012).
- [28] Cherry, E., Czerwinski, M., Roseway, A., Kapoor, A., Johns, P., Rowan, K. and Schraefel, m.: Food and Mood: Just-in-Time Support for Emotional Eating, (online), DOI: 10.1109/ACII.2013.48 (2013).
- [29] Russell, D. W.: In search of underlying dimensions: The use (and abuse) of factor analysis in Personality and Social Psychology Bulletin, *Personality and social psychology bulletin*, Vol. 28, No. 12, pp. 1629–1646 (2002).
- [30] Ferreira, D., Kostakos, V. and Dey, A.: AWARE: Mobile Context Instrumentation Framework, *Frontiers in ICT*, Vol. 2 (online), DOI: 10.3389/fict.2015.00006 (2015).
- [31] NorthCube AB.: Sleep Cycle alarm clock, NorthCube AB. (accessed 2016-05-26).
- [32] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V. et al.: Scikit-learn: Machine learning in Python, *Journal of machine learning research*, Vol. 12, No. Oct, pp. 2825–2830 (2011).