

ユーザ嗜好と血糖値を考慮した高血糖抑制支援システムの実現と評価

道浦菜々子[†] 松田 裕貴[†] 諏訪 博彦[†] 安本 慶一[†]

[†] 奈良先端科学技術大学院大学 〒630-0101 奈良県生駒市高山町 8916-5

E-mail: †{michiura.nanako.mo2,yukimat,h-suwa,yasumoto}@is.naist.jp

あらまし 近年、糖尿病患者のための高血糖抑制のための自己管理システムの開発が盛んに行われている。しかし、糖尿病を発症する前の健常者を支援する手法は、ほとんど存在しないのが現状である。糖尿病は一度発症すると寛解しても完治しないため、糖尿病を発症する前に防ぐことが必要不可欠である。そこで本研究では、リアルタイムに血糖値を把握しながら、摂取予定の食事内容が高血糖になると予測した場合に、ユーザ嗜好を考慮した上で摂取量を減らすべき食品を算出し、その結果をユーザへ提示する高血糖抑制支援システムを提案する。本稿では、提案システムの実現可能性を調査するための実験設計と血糖値予測モデルの構築・評価を行った。血糖値予測モデルの構築にあたっては、2時間後の血糖値を予測することを目的とし、被験者 10 名から血糖値に影響があるとされるデータ（食事情報、睡眠情報、被験者の身体情報）を収集した。血糖値予測モデルの評価を行った結果、最も精度の高い被験者において RMSE（二乗平均平方根誤差）は 7.66、MAE（平均絶対誤差）は 4.66 となることが示された。

キーワード 血糖値予測, 食事摂取量推薦, 高血糖抑制

Implementation and Evaluation of a Hyperglycemia Control Support System Considering Both User Preference and Blood Glucose Level

Nanako MICHIUURA[†], Yuki MATSUDA[†], Hirohiko SUWA[†], and Keiichi YASUMOTO[†]

[†] Nara Institute of Science and Technology 8916-5 Takayama-cho, Ikoma, 630-0101 Japan

E-mail: †{michiura.nanako.mo2,yukimat,h-suwa,yasumoto}@is.naist.jp

Abstract In recent years, there has been much effort to develop self-management systems to control hyperglycemia for diabetic patients. However, there are few ways to help non-diabetic people avoid becoming diabetics. Since diabetes cannot be completely cured even after remission, it is necessary to prevent diabetes before it develops. In this paper, we propose a system to support the prevention of diabetes by monitoring blood glucose levels in real-time, calculating the foods to be reduced in consideration of the user's preferences, and presenting them to the user when the system predicts that the planned meal will cause hyperglycemia. In this paper, we design an experiment to investigate the feasibility of the proposed system and construct and evaluate a model for predicting blood glucose levels. To construct the blood glucose prediction model, we collected data (dietary information, sleep information, and physical information of the subjects) from ten participants to predict blood glucose levels two hours later. The results show that the constructed model could predict blood glucose levels with RMSE of 7.66 and MAE of 4.66.

Key words Blood Glucose Prediction, Dietary intake recommendation, Hyperglycemia control

1. はじめに

現在、生活習慣に起因する慢性疾患の 1 つである糖尿病が急速に増加している。厚生労働省によると [1], 糖尿病が強く疑われる者（糖尿病有病者）と糖尿病の可能性を否定できない者（糖尿病予備軍）は、合計約 2,200 万人と推計され、日本国民の 5 人に 1 人が該当するという深刻な状況である。糖尿病は一度発症すると寛解しても完治しないため、糖尿病を発症する前に

防ぐことが必要不可欠である。健常者の場合は、血糖値の上昇に伴い適切な量のインスリンが分泌されるため、食事 2 時間程度で血糖値の正常範囲内である、70~140 mg/dL まで低下するが、糖尿病予備軍の場合、インスリンが分泌されていても正常に働かなくなることによる「食後高血糖」が起こる。この食後高血糖が頻繁に起こると、糖尿病を引き起こす可能性が高いと言われており、糖尿病予備軍にとって糖尿病判定の重要な指標となっている。しかし、通常食事抜きで行われる健康診断では、

食後高血糖が検知されにくく、糖尿病が進行した状態でなければ、空腹時の血糖値は糖尿病の基準に到達しないため、診断から漏れてしまう可能性が非常に高い。

また、糖尿病には遺伝素因が主な原因となっている I 型糖尿病と、遺伝素因に肥満、過食、運動不足、ストレスといった環境素因が加わって発症する II 型糖尿病の 2 種類に分類され、現在の日本では糖尿病患者の 90 % 以上が II 型糖尿病を発症している。そのため糖尿病を未病の段階で予防するには、環境素因に対する継続的な自己管理が必要であるといえる。糖尿病の自己管理は主に、正常範囲内の血糖値の維持、食後血糖値の上昇を示す指標である GI 値 (Glycemic Index) の低い食品を中心とした健康的な食事、定期的な運動、そして禁煙が挙げられる。

本研究では、血糖値の変動が激しい食事における継続的な自己管理を目的として、摂取予定の食事から血糖値の上昇を事前に予測し、ナッジを用いて摂取量を減らすべき食品をフィードバックする高血糖抑制支援システムを提案する。減らすべき食品の提示は、モバイルデバイスの利用を軸としてシステムを構築することで、ユーザの手軽な利用・参加を実現する。また、提案システムの実現可能性を調査するための 2 つの実験設計を行った。実験 1 では、2 時間後の血糖値を予測することを目的として、被験者 10 名から血糖値に影響があるとされるデータ (食事情報、睡眠情報、被験者の身体情報) を収集し、各被験者の血糖値予測モデルを構築する。実験 2 では、実験 1 で作成した血糖値予測モデルを用いて、実際に提案システムを使用してもらい、食事行動の変化や血糖値への影響、システムの有用性を評価する。本稿では、実験 1 について評価結果を示す。

実験 1 の結果として、個人のデータを用いて構築されたモデルにおいては、最も精度の高い被験者で RMSE (二乗平均平方根誤差) が 7.66, MAE (平均絶対誤差) が 4.66 となることを確認した。一方で、一般化したモデルにおいては精度の低下が見られたため、その原因について考察している。

以降の章構成は、以下の通りである。第 2 章では糖尿病自己管理システム、ナッジを用いた高血糖抑制支援に関連した既存研究を概説すると共に、関連研究の課題と本研究の位置づけを述べる。第 3 章では提案手法を述べ、第 4 章で実験設計と結果について述べる。最後に第 5 章で本稿のまとめと今後の展望を述べる。

2. 関連研究

本節では、本研究に関連する糖尿病自己管理システムとナッジを用いた食事行動変容についての既存研究を概観する。

2.1 糖尿病自己管理システムに関する研究

Alfian らの研究 [2] では、リアルタイムデータ処理、機械学習アルゴリズムを用いて糖尿病患者の慢性的な状態を自己管理するためのモニタリングシステムを提案している。BLE ベースのセンサを用いて血圧、心拍数、体重、血糖値などのバイタルサインデータをスマートフォンに収集している。血糖値の収集には、穿刺型の血糖値測定機器を用いているため、データ収集の度に穿刺が必要である。この研究では、70 名の糖尿病患者からデータを収集し、糖尿病の分類と血糖値予測が行われてい

る。血糖値予測には、LSTM と線形回帰が用いられており、血糖値予測の評価では、LSTM の RMSE は 25.621, 線形回帰の RMSE は 44.069 となっている。

Pooja らの研究 [3] では、個人特化型の血糖値予測を表示するスマートフォンのアプリケーション GlucOracle を開発している。このアプリケーションは、摂取した食事に応じた血糖値の変化を予測し、食事時の意思決定を支援することを目的としている。この目的を実現するために、ユーザに食事画像とその内容のテキスト入力、さらに食前と食事 2 時間後の血糖値データを収集している。収集したデータを血糖値予測のための訓練データとして学習し、食後 3 時間以内の血糖値の最低値から最高値までの範囲を予測し、画面上に表示する。また、食事画像から栄養素を推定する機能も搭載してあるため、栄養評価を受けることも可能である。

Calle-Bustos らの研究 [4] では、約 70 名の 5 歳から 14 歳の糖尿病患者を対象に、糖尿病患者の継続的な治療教育を支援することを目的として、食事に含まれる糖質量を AR で提示する、iOS/Android 端末向けアプリケーションを開発している。このアプリケーションは、皿の絵をマーカーとし、その上に果物やパンのアニメーションを合成し、ゲーム形式で様々な食品の炭水化物含有量を学習することが可能である。

2.2 ナッジを用いた高血糖抑制支援に関する研究

近年、行動経済学 (ナッジ) の利用がどのように食事・自己管理の行動に影響を与えることができるかを調査する研究が多数行われている [5]~[8]。ここでいうナッジとは、Thaler らによって提案された行動経済学の概念であり [9]、強制的に導こうとする思想 (Paternalism) と自主性に委ねる思想 (Libertarianism) の融合である。人々の選択の自由を妨げたり、選択を制限することなく自身にとって最適な選択へ誘導することを目指している。Arno らの研究 [6] では、食事行動の影響を与えるナッジの有効性を調査している。参加者による健康的な食事や栄養の選択において、平均 15.3 % 増加しており、ナッジは個人の食事選択の改善に有効であると示唆されている。

また、Joachim らの研究 [10] では、糖尿病患者の継続的な自己管理を目的として、ナッジを用いた自己管理プラットフォームを開発している。患者はモバイルアプリで撮影した食事画像をアップロードすることで、食事画像が畳み込みニューラルネットワークを用いて解析されたのち、食品の栄養情報を確認することができる。また、アップロードされた食事画像と患者の血糖値を考慮した食事の提案内容を確認することができる。以上の機能により、患者の食事摂取が改善されることから、この研究はナッジに基づくものとして認識されている。

2.3 関連研究の課題

既存研究では、糖尿病患者を対象とした自己管理システムが多く、糖尿病を発病する前の健常者を支援する手法はほとんど存在しない。また、血糖値予測の際に、穿刺性の器具により離散的な血糖値データを用いているため、ユーザへの負荷が大きい点や予測の精度が低い点、血糖値上昇を考慮して、実際にこれから食事をする際の推薦摂取量のフィードバックがない点が問題点として挙げられる。糖尿病の発症そのものを防ぐには、

高精度な血糖値予測だけでなく、高血糖抑制のため血糖値が上がりやすい食事をしないように促すことで、血糖値の上昇を抑制する自己管理システムが必要である。

こうした問題点を踏まえて、本研究では、ユーザの摂取した食事履歴、摂取予定の食事情報、最終食事からの経過時間、睡眠時間、BMIなどのユーザデータ、リアルタイムで測定した血糖値データから、被験者の食事2時間後の血糖値を予測する。その上で高血糖とされる閾値を超える場合には、各食品の推薦摂取量をナッジを用いてフィードバックすることで、高血糖状態を避けるような食事行動を促す新たなシステムの実現を目指す。

3. 提案手法

本章では、提案システムの要件と構成について述べる。

3.1 システムの概要と要件

本研究では、個人ごとの血糖値予測モデルを使って、摂取予定の食事による血糖値の上昇を事前に予測し、ナッジを用いた高血糖状態を避ける食事の行動変容を可能とする新たなシステムを提案する。関連研究の課題から、提案システムを実現するには、以下の要件を満たす必要がある。

- (1) ユーザの負担なく連続的に血糖値データを収集できること
- (2) ユーザの嗜好と血糖値モデルを反映していること
- (3) 各食品の適正な摂取量を食前に提示できること
- (4) 行動変容の仕組みがあること

これらの4つの要件を満たすことで、ユーザは日常生活で継続的にシステムを利用できる。

3.2 システムの構成

図1に提案システムの構成を示す。提案システムは1)データ収集、2)データ分析、3)フィードバックから構成される。データ分析では、収集したデータから血糖値の予測モデルを構築後、行動変容に向けた食品・量の予測を行う。各構成部分の具体的な役割は以下に示す。

3.3 データ収集

Woldaregayらの研究[11]では、血糖値には食事の摂取、BMI (Body Mass Index, ボディマス指数)、ストレス、炭水化物摂取量、睡眠時間、病気の有無、投薬、喫煙習慣、アルコール依存症、アレルギーなどが影響を与えると報告されている。本システムでは、データ収集用に開発したアプリケーション[12]を用いて血糖値、食事情報、睡眠時間、およびBMIなどのユーザデータを収集する。開発したアプリケーションは、ユーザが撮影した食事画像や食事開始時間、就寝および起床時間、BMIなどのユーザデータを収集することができる。

食事情報のデータ収集では、スマートフォンで食事の画像を撮影し、食事画像の各食品(およびカロリー)を高精度に識別するサービスFoodLog¹を用いて、画像中の各食品を識別する。識別後、各食品の糖質量とGI値を抽出し、最後に食事画像を撮影した時間から食後経過時間を算出する。

睡眠のデータ収集では、ユーザが起床もしくは就寝をアプリケーション上のボタンをクリックすることで、自動的に送信時

間をラベリングされる。ラベリングされた起床時間と就寝時間から睡眠経過時間を算出する。

血糖値のデータ収集では、24時間連続で収集可能なFreestyle リブレ²を用いて継続的に取得する。Freestyle リブレを図2に示す。センサに付随している小さな針を皮膚の上層部に刺すことで、血糖値を間接的に測定することが可能である。また、サイズが小さいため、装着時と装着中にほとんど痛みを与えずデータを収集することが可能である。本システムでは、センサデータをBluetoothを介してスマートフォンに送信可能なBluCon³をFreestyle リブレに被せることで、自動的に血糖値データを収集する。BluConはFreestyle リブレの血糖値データをNFC(近距離無線通信)で取得し、BLE(Bluetooth Low Energy)でデータを送信することができるデバイスとなっており、5分単位で自動的にデータ収集可能である。

ユーザのデータ収集では、嗜好情報と身体情報を収集する。嗜好情報は開発したアプリケーションで好きな食品を入力し、入力された食品の特徴を分析する。分析した嗜好の特徴データを他の食品に応用させることで嗜好度合いを算出する。また、身体情報では、個人の身体的特徴を表す指標として、基礎代謝とBMIを用いる。これらは、性別・年齢・身長・体重の4つの情報を用いることで算出できるため、アプリケーションを介してユーザから収集する。

3.4 血糖値予測モデル

図1(中央上)のデータ分析では、収集したデータから食事2時間後の血糖値を予測するモデルを構築する。Tamakiらの研究[13]では、食後血糖値の上昇を示す指標であるGI値に着目し、RandomForestを用いた血糖値予測モデルを構築している。本システムも同様の手法を用いて個人の血糖値予測モデルを構築する。また、Obaらの研究によると[14]、GL(Glycemic Load)値は女性において、またGI値は総脂肪摂取量の多い男性において、II型糖尿病の発症リスクと正の相関があると述べている。そこで本研究では、新たな特徴量として、食事中に摂取する食材ごとの糖質量に合わせた食後血糖値の上昇を示す指標であるGL値を使用する。GL値は以下の式で表される。

$$GL = \frac{\text{食品摂取量に含まれる炭水化物量 (g)} \times \text{食品の GI 値}}{100}$$

3.5 食品・量の選定

図1(中央下)のデータ分析では、高血糖状態回避のための食品・量を選定する。個人の血糖値予測モデルと入力された食事画像データから、食品を全て食べた際に食後高血糖が発生すると予測した場合、各食品の摂取量を減らすことで、血糖値の上昇を抑える。食品摂取量の減らし方として、目的関数を設定し、血糖値の上昇に制約を与えた線形計画問題として定式化し最適解を求める方法が考えられるが、ここでは、簡単かつ短時間で算出する方法として、ユーザの嗜好を優先した欲張り法と品目数が最大となるように考慮した品目数優先法の2種類のアルゴリズムを採用した。ユーザの嗜好を優先した欲張り法では、

(注2) : <https://www.myfreestyle.jp/>

(注3) : <https://cgm.ambrosiasys.com/>

(注1) : <https://www.foo-log.co.jp/>

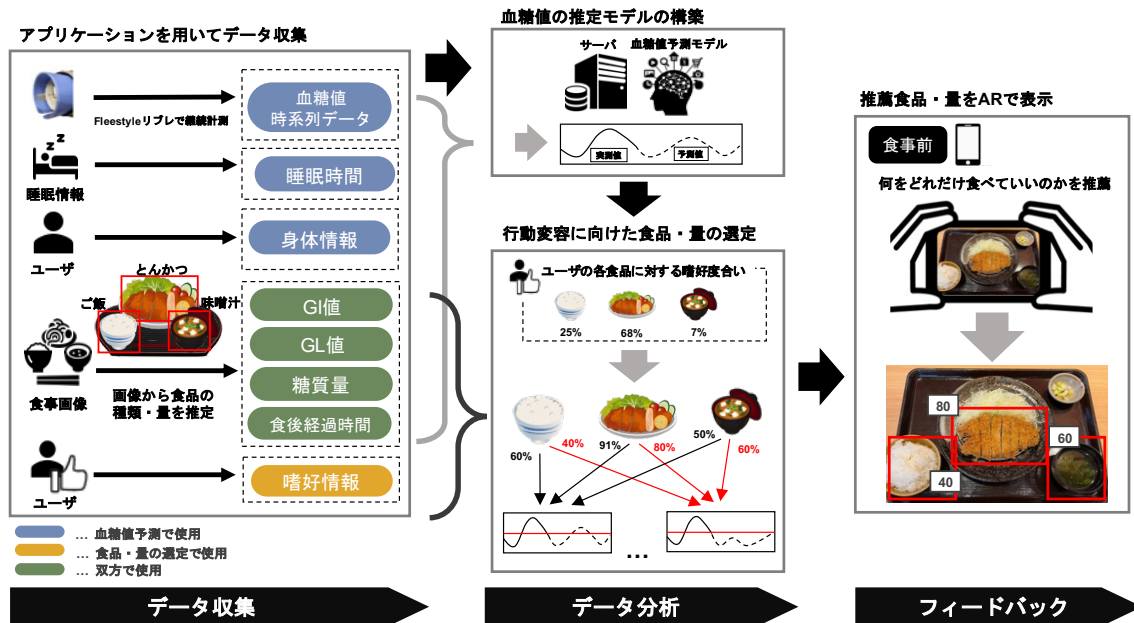


図 1: 提案システムの構成

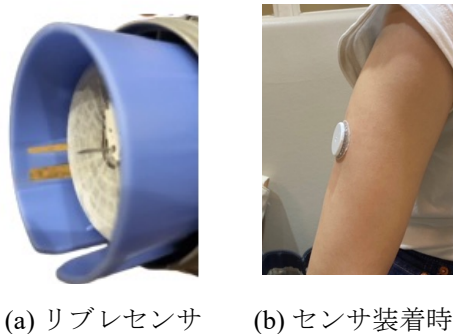


図 2: 血糖値測定機器 (Freestyle リブレ)

各食品に対して全ての値を足した場合に 100 となる嗜好度を与えられており、各食品の嗜好度に対する食後血糖値上昇度を算出し、単位嗜好度あたりに対する食後の血糖値上昇度が最も高い食品の摂取量を 5% ずつ減らしていく。品目数が最大となるように考慮した品目数優先法は、最も高い食後の血糖値上昇度の食品から順番に摂取量 5% を減らしていく。双方のアルゴリズムは糖尿病予備軍の指標となる食後 2 時間後の血糖値状態が 140 mg/dL 以下となるような各食品の組み合わせを算出する。

3.6 ナッジを用いたフィードバック

図 1 の右にあるフィードバックでは、食品と量の選定結果をナッジを用いて可視化する。可視化の際は、データ収集に使用したアプリケーションを用いる。配膳された食事をスマートフォンで撮影することで、食後高血糖を回避する摂取量を各食品の画像上に重畳して表示する。また、推薦量の結果とともに、ナッジとして「アプリ使用者の 86% は、この推薦摂取量に従っています。」といったメッセージを表示する。Caraban の研究によると [15], ナッジ手法は 23 種類存在し、大きく分けて 6 つのカテゴリーに分類される。本研究では、その中の Social Influence に分類される Enabling Social Comparisons のナッジ手

法を採用した。これは人間が適切な行動をすることが決断できない時に、他人の行動に意識が向き、「他人がとる行動は正しい行動である」という社会的証明の原理を利用したものである。実験では実際にユーザーに食事をしてもらい、推薦摂取量に従うかどうかを評価する。

4. 実験設計

4.1 実験概要

血糖値予測モデルの構築にのための実験 (実験 1) と、提案システムを用いて実際に食事をしてもらう実験 (実験 2) を設計する。実験 1 では、約 2 週間非糖尿病患者である成人男性 10 人を対象に、血糖値に影響のあるデータを収集し、個人ごとの血糖値予測モデルを構築した。血糖値予測モデルの予測値と実測値から RMSE (二乗平均平方根誤差) と MAE (平均絶対誤差) を基準として、予測モデルの有用性を評価する。実験 2 では、実験 1 と同様の被験者を対象に、これから摂取する食事に対して、食品・量の選定アルゴリズムを適応して、推薦摂取量をナッジを用いて表示するシステムを実際に使用してもらう。推薦摂取量提示後にどの程度従ったのか、食事 2 時間後の血糖値、システム使用後のアンケートから提案システムの実用性を評価する。

4.2 実験方法

4.2.1 実験 1: 血糖値予測モデル構築のためのデータ収集

実験 1 では、各被験者に Freestyle リブレを装着してもらい、リアルタイムな血糖値データを収集しながら、食事内容、睡眠時間をアプリケーションに入力してもらう生活を 2 週間送ってもらう。Freestyle リブレは、センサ装着している間 15 分単位で血糖値を自動的に収集する。1 つのセンサで 2 週間分のデータを収集することができる。食事情報の収集では、食事画像から料理名や糖質量、カロリーを算出し、受信した画像は自動的に送信時間がラベリングされる。ラベリングされた時間を食事

表 1: 機械学習に使用する特徴量一覧

特徴量	内容
血糖値	データを収集した時の血糖値の値
カロリー	各食品のカロリーの総和
糖質量	各食品の糖質量の総和
GI 値	各食品の血糖値上昇指数の総和
GL 値	各食品の糖質量に合わせた血糖値上昇指数の総和
食事経過時間	食事した時間から次の食事までの時間 (分)
睡眠情報	昼寝も含めた睡眠時間 (分)

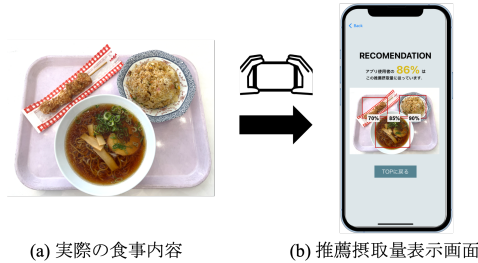


図 3: 推薦摂取量とナッジの表示画面

開始時間とする。また、GI 値の算出には GI 値データベースであるシドニー大学の Search for the Glycemic Index⁴を使用する。各被験者の血糖値予測モデルを構築する際に使用した特徴量を表 1 に示す。カロリーや糖質量、GI 値、GL 値については、食事中に含まれる各食品の合計値とする。得られた特徴量を用いて、食事 2 時間後の血糖値を予測するモデルを構築する。まず、Hold-out 法 (8:2 で分割) によって各被験者に特化したモデル (個人モデルと称する) を構築する。また、Leave-one-person-out 法によって一般化したモデル (LOPO モデルと称する) を構築する。

4.2.2 実験 2: 食品・量の選定方法による効果検証

実験 2 では、各被験者に Freestyle リブレを装着してもらい、リアルタイムな血糖値データを収集しながら、3 日間の昼食を指定した食事で摂取してもらおう。実際に摂取してもらった食事内容と推薦摂取量が表示されるアプリケーション画面を図 3 に示す。被験者には食事前に食事画像を撮影してもらい、食後にも同じ画角で撮影してもらおう。1 回目の昼食は推薦摂取量とナッジの表示はされず、2 回目以降の昼食で推薦摂取量及びナッジが表示される。2 回目の昼食では、ユーザの嗜好を優先した欲張り法で算出した各食品の推薦摂取量とナッジを表示し、3 回目の食事では、品目数が最大となるように考慮した品目数優先法で算出した各食品の推薦摂取量とナッジを表示する。本実験では、選定方法による効果検証が目的のため、睡眠時間などの他の影響要因については、できるだけ統一してもらおうようにしている。

4.3 実験結果

本稿では前節で設計した実験のうち、実験 1 の結果を報告する。血糖値予測モデルの評価結果を表 2 に示す。機械学習アルゴリズムには RandomForest を用いた。なお、LOPO モデルに

表 2: 各被験者の予測モデルの評価

モデル種別	被験者 ID	RMSE [mg/dl]	MAE [mg/dl]
個人モデル	A	11.68	7.47
	B	7.64	5.29
	C	10.88	7.38
	D	17.51	11.25
	E	13.18	7.73
	F	8.55	5.81
	G	11.09	7.04
	H	7.66	4.66
	I	8.07	5.83
	J	10.35	7.34
	平均	10.66	6.98
LOPO モデル		21.34	16.17

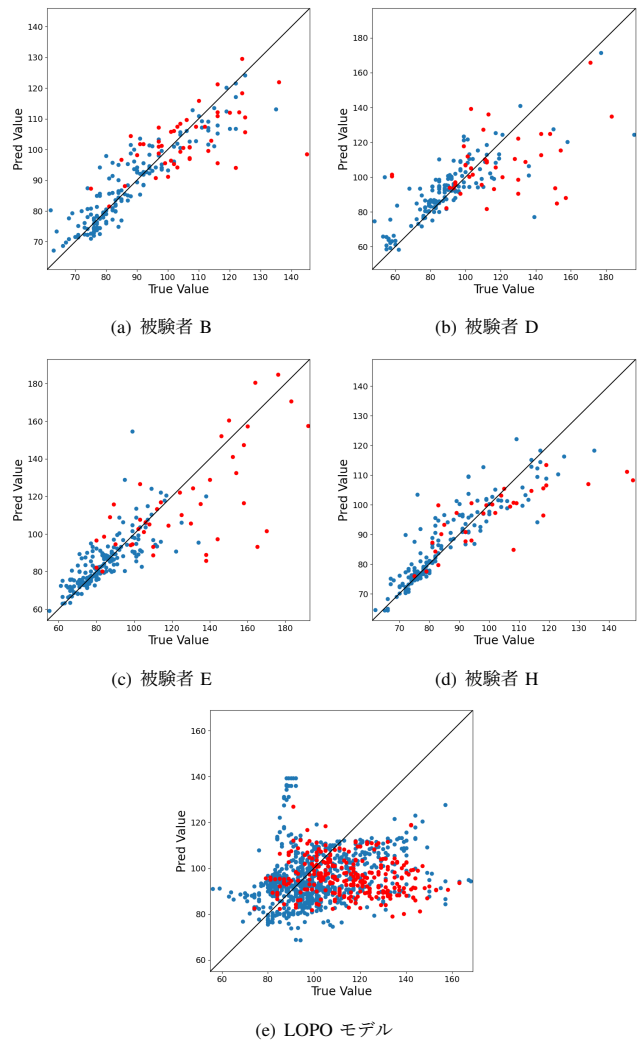


図 4: 被験者 B, D, E, H モデル及び LOPO モデルの精度

ついては交差検証の結果を示している。表 2 には、構築したモデルの RMSE (二乗平均平方根誤差) と MAE (平均絶対誤差) を計算した結果を示している。各被験者のモデルを評価した結果、被験者 H のモデル精度が最も高い結果となった。また、LOPO モデルでは、各被験者のデータセットで構築したどのモデルよりも精度が低い結果となった。今回の被験者の中でモデル

(注 4) : <https://www.glycemicindex.com/>

精度が低い被験者 D, E とモデル精度が高い被験者 B, H のモデル評価 (全ての推定結果の散布図) を図 4 に示す. ここでは, 食事開始から食事 2 時間後までのテストデータを赤点, その他を青点で示すことにより, 提案システムで重要視される食事 2 時間後のモデル精度を明示した. 図 4 に示した被験者 4 名ともに, 食事 2 時間以内に血糖値が 140 mg/dl を超えているケースがあり, また高血糖領域である 140 mg/dl 以上の実測値に対し, 血糖値予測モデルは低い値を予測していることがわかる.

4.4 考 察

表 2 より, 被験者 D と E のモデル精度は RMSE が 13.18 以上で, モデル精度が最も低い結果となった. 要因として, 間食の回数や摂取時間が挙げられる. 被験者 D や E は食後に間食をすることが多く, メインの食事後に間食を摂取した時を特徴量として考慮ができていないため, モデルの精度に大幅な差が生じたと考えられる. 今回の実験ではメインの食事以外に間食の回数を設けずに行ったため, 血糖値が下がった状態の時に間食をしている被験者のモデル精度は高いが, 間食の回数が多く, 特に食後に間食をする被験者のモデル精度が低くなるという結果となった. また, LOPO モデルは, どの被験者の個人モデルよりも精度が低い結果となった. これは食事をした際に血糖値の上昇スピードなどが人それぞれ異なることが原因と考えられる. そのため, 提案システムを実現するにあたり, 各ユーザーに合わせた血糖値予測モデルが必要であることがわかった. その上で, 被験者 B や H のモデル精度はシステムへの利用可能な精度を示していることがわかった.

また, 図 4 より, 高血糖領域である 140 mg/dl 以上の実測値を血糖値予測モデルは低く予測している. 例えば, 図 4 の被験者 E は, 血糖値 140 mg/dl 付近の値を 90 mg/dl から 120 mg/dl で推測している. 原因として, 被験者が摂取する食事の糖質量と摂取カロリーの換算に原因があると考えられる. 本システムでは, 画像認識を用いて食事画像中の各食品を識別し, 一人前の摂取カロリーと糖質量を収集している. しかし, 被験者が画像上に写っている食品以外を食べている場合や食事画像を撮影する際にオクルージョンが発生している場合などは, 予測値が実測値より低くなってしまふ. 適した推薦摂取量を推薦するためには, 入力した食事画像から正確な糖質量と摂取カロリーを収集する必要がある.

5. ま と め

生活習慣病の一種である糖尿病を未然に防ぐために, 本研究では, 血糖値の変動が激しい食事に着目し, 健常者の食品嗜好とリアルタイムな血糖値を考慮した高血糖抑制支援システムを提案した. 本稿では, 血糖値に影響があるとされる食事情報, 睡眠情報, 被験者の身体情報を対象にデータ収集し, 血糖値予測モデルの特徴量とした. GI 値だけでなく GL 値を用いて, 実際に摂取した食品の量を加味した血糖値の上昇度合いを考慮した結果, Tamaki らの研究 [13] と比較して, モデルの精度が向上し, システムへの応用の可能性を示した.

今後は, 実験 1 と同様の被験者で実験 2 の食品・量の選定とナッジの適応実験を行う予定である. 実験を通して, システム

に組み込んだ食品・量の選定アルゴリズムがユーザーに受け入れやすいものか, 実際にナッジを用いて提示された推薦摂取量に対しての被験者の食事行動の変化や, 食事行動の変化による血糖値への影響を評価し, 有用性を検証する.

謝 辞

本研究は, JSPS 科研費基盤研究 JP21K19828 の助成を受けたものです. また, 本研究の実験は, foo.log 株式会社の協力の下で実施されたものです. ここに感謝の意を申し上げます.

文 献

- [1] 厚生労働省, “令和元年国民健康・栄養調査報告,” <https://www.mhlw.go.jp/content/000711007.pdf>, 2020.
- [2] G. Alfian, M. Syafrudin, M.F. Ijaz, M.A. Syaekhoni, N.L. Fitriyani, and J. Rhee, “A personalized healthcare monitoring system for diabetic patients by utilizing ble-based sensors and real-time data processing,” *Sensors*, vol.18, no.7, p.2183, 2018.
- [3] P.M. Desai, E.G. Mitchell, M.L. Hwang, M.E. Levine, D.J. Albers, and L. Mamykina, “Personal health oracle: Explorations of personalized predictions in diabetes self-management,” *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, pp.1–13, 2019.
- [4] A.-M. Calle-Bustos, M.-C. Juan, I. García-García, and F. Abad, “An augmented reality game to support therapeutic education for children with diabetes,” *PloS one*, vol.12, no.9, p.e0184645, 2017.
- [5] T.M. Marteau, D. Ogilvie, M. Roland, M. Suhrccke, and M.P. Kelly, “Judging nudging: can nudging improve population health?,” *BMJ*, vol.342, pp.1–10, 2011.
- [6] A. Arno and S. Thomas, “The efficacy of nudge theory strategies in influencing adult dietary behaviour: a systematic review and meta-analysis,” *BMC public health*, vol.16, no.1, pp.1–11, 2016.
- [7] M. Li and G.B. Chapman, “Nudge to health: Harnessing decision research to promote health behavior,” *Social and Personality Psychology Compass*, vol.7, no.3, pp.187–198, 2013.
- [8] R. Nakaoka, Y. Nakamura, Y. Matsuda, S. Misaki, and K. Yasumoto, “eat2pic: Food-tech design as a healthy nudge with smart chopsticks and canvas,” *2021 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*, pp.389–391, 2021.
- [9] C.L. Thomas, H.T. Richard, and R.S. Cass, “Nudge: Improving decisions about health, wealth, and happiness,” *Constitutional Political Economy*, vol.19, no.4, pp.1–5, 2008.
- [10] S. Joachim, A.R.M. Forkan, P.P. Jayaraman, A. Morshed, and N. Wickramasinghe, “A Nudge-Inspired AI-Driven Health Platform for Self-Management of Diabetes,” *Sensors*, vol.22, no.12, p.4620, 2022.
- [11] A.Z. Woldaregay, E. Årsand, S. Walderhaug, D. Albers, L. Mamykina, T. Botsis, and G. Hartvigsen, “Data-driven modeling and prediction of blood glucose dynamics: Machine learning applications in type 1 diabetes,” *Artificial intelligence in medicine*, vol.98, pp.109–134, 2019.
- [12] 道浦菜々子, 松田裕貴, 諏訪博彦, 安本慶一, “AR とナッジを用いた高血糖抑制のための食事行動変容システムの検討,” *情報処理学会関西支部 支部大会 講演論文集*, pp.1–8, 2022.
- [13] R. Tamaki, M. Fujimoto, H. Suwa, and K. Yasumoto, “Data Analysis for Developing Blood Glucose Level Control System,” *Adjunct Proceedings of the 2021 International Conference on Distributed Computing and Networking*, pp.104–109, 2021.
- [14] S. Oba, A. Nanri, K. Kurotani, A. Goto, M. Kato, T. Mizoue, M. Noda, M. Inoue, and S. Tsugane, “Dietary glycemic index, glycemic load and incidence of type 2 diabetes in japanese men and women: the japan public health center-based prospective study,” *Nutrition journal*, vol.12, no.1, pp.1–10, 2013.
- [15] A. Caraban, E. Karapanos, D. Gonçalves, and P. Campos, “23 ways to nudge: A review of technology-mediated nudging in human-computer interaction,” *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, pp.1–15, 2019.