

血糖値予測精度向上に向けたデータ分析と 摂食速度の影響調査

道浦 菜々子¹ 松田 裕貴¹ 諏訪 博彦¹ 安本 慶一¹

概要: 現在の日本では、糖尿病有病者と糖尿病予備軍は 2200 万人にのぼり、日本人の 5 人に 1 人が該当している。食事 2 時間後の血糖値が下がらない状態である食後高血糖は、II 型糖尿病をはじめとする生活習慣病を引き起こす原因となるため、食事をはじめとした環境素因に対する継続的な自己管理が必要不可欠である。著者らはこれまで、摂取予定の食事から食後高血糖を予測し、各食品の推薦摂取量をフィードバックする自己管理システムを提案してきた。しかし、高血糖領域の予測精度が不十分であることや摂食速度や順番といった食べ方の影響が考慮されていないという課題がある。そこで、本稿では、血糖値予測モデルの精度向上と摂食速度・順番の影響の解明に向けたデータ分析を行う。具体的には、精度向上に向けた血糖値予測モデルを構築する実験 1 と、摂食速度の違いによる血糖値への影響を調査する実験 2 を行った。実験 1 では、血糖値に影響があるとされるデータから抽出した特徴量に加え、食事 30、60、90 分後の予測値を使用した結果、全被験者に対して予測精度が向上した。最も精度の高い被験者で RMSE (二乗平均平方根誤差) が 11.26、MAE (平均絶対誤差) が 7.98 となることを確認した。また、収集したデータおよびモデル精度の分析を行った結果、高 GI 食品の摂取や身体活動を新たな特徴量として追加することで、更なる予測精度向上の可能性を示した。実験 2 では、摂食速度と順番を変更して指定した食事を摂取してもらった結果、早い摂食は若年層でも食後高血糖の発生や、一度上昇した血糖値が下がらない傾向を確認した。

1. はじめに

II 型糖尿病は生活習慣に起因する慢性疾患の 1 つであり、世界的な糖尿病人口は 2045 年までに約 7 億人に達すると予測されている [1]。II 型糖尿病は一般的に高齢で発症する病気であるが、近年では、若年層の割合が増加傾向にある [2]。原因として、不健康な食事の摂取や運動不足の増加により、ボディマス指数 (BMI) や空腹時血糖値の上昇が挙げられる [3]。症状の悪化に伴い、神経障害や網膜症などの合併症を引き起こし、最悪の場合死に至る可能性がある。II 型糖尿病は、一度発症すると寛解しても完治しないため、発症する前の段階で予防することが必要不可欠であるといえる。

現在の日本では、糖尿病患者の 90 % 以上が遺伝素因と環境素因が主な原因となっている II 型糖尿病を発症している。環境素因とは、肥満や過食、運動不足、ストレスといった生活習慣の乱れのことを指す。また、厚生労働省によると [4]、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 人が該当する深刻な

状況である。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いことによる「食後高血糖」が発生する。この食後高血糖が頻繁に発生すると、糖尿病を引き起こす可能性が高まるため、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。そのため、食後高血糖の発生を予防するような環境素因に対する継続的な自己管理を行い、糖尿病を引き起こさない血糖値へコントロールする必要がある。糖尿病の自己管理は主に、正常範囲内の血糖値の維持、健康的な食事、定期的な運動、そして禁煙が挙げられる。

著者らは、これまでに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、リアルタイムに血糖値を測定しつつ、摂取予定の食事から食後高血糖を事前に予測し、各食品の推薦摂取量をフィードバックすることで血糖値のコントロールを可能とする自己管理システムの開発に取り組んできた [5]。専用アプリケーションと持続血糖測定 (CGM: continuous glucose monitoring) が可能なセンサを使用し、血糖値に影響があるとされるデータ (食事情報、睡眠情報、身体情報) と食後の急峻な血糖値上昇を含む連続的な血糖値データを用いて、食後高血糖を判定するため

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology

に、2時間後の血糖値を予測するモデルの精度を評価している。しかし、高血糖領域の予測精度が不十分であることや、血糖値の上昇を促進するとされる摂食速度や順番 [6] といった食べ方の影響が考慮されていない。

以上の背景から、本稿では、血糖値予測モデルの精度向上と摂食速度・順番のデータ分析を行うことを目的とし、2つの実験設計を行った。実験1では、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）から抽出した特徴量に加え、食事30、60、90分後の予測値を使用した結果、予測精度が向上した。最も精度の高い被験者でRMSE（二乗平均平方根誤差）が11.26、MAE（平均絶対誤差）が7.98となることを確認した。また、収集したデータおよびモデル精度の分析をした結果、高GI食品の摂取や身体活動を新たな特徴量として追加することで、更なる予測精度向上の可能性を示した。実験2では、被験者4名を対象に摂食速度と順番を変更して指定した食事を摂取してもらった結果、早い摂食は若年層でも食後高血糖の発生や、一度上昇した血糖値が下がらない傾向を確認した。

2. 関連研究

本章では、本研究に関連する血糖値測定・予測、糖尿病自己管理システムについて、既存研究を概観する。

2.1 血糖値測定・予測

Waghmareの研究[7]では、糖尿病のスクリーニングやモニタリングへの使用を目的とした自己血糖測定（SMBG: self-monitoring blood glucose）デバイス GlucoScreenを開発している。このデバイスをスマートフォンに貼り付け、先端に血液を少量垂らすことで、手軽に1回分の血糖値測定が可能である。また、市販の血糖試験紙の読み出しに携帯電話のタッチスクリーンを利用している点や、エネルギーの供給には携帯電話のフラッシュから採取しているため、機種に依存せずどのスマートフォンでも使用することが利点である。

Alfianらの研究[8]では、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で血糖値予測を行っている。BLE（Bluetooth Low Energy）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センサノードから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。

しかし、これらの既存研究では、SMBGデバイスの使用により血糖値の収集のたびに穿刺する必要があるため、長

期間における糖尿病モニタリングの場合は患者への負担が極めて大きいことや、離散的なデータの使用により血糖値の予測精度が低いという問題点がある。

2.2 糖尿病自己管理システム

II型糖尿病の自己管理のために、主に運動や行動、食事、臨床医とのコミュニケーションに焦点を当てたシステムが数多く開発・研究されている[9], [10], [11], [12], [13], [14]。特に食事に焦点を当てた糖尿病自己管理システムにおいて、Calle-Bustosらの研究[9]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（carb）含有量を学習することが可能である。

Joachimらの研究[14]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、畳み込みニューラルネットワークを用いて解析され、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担当の臨床医がWebアプリケーションを通して確認することが可能であるため、患者に合わせた食事を提案することができる。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。

血糖値の改善に不可欠なものとして、(i) コミュニケーション、(ii) 患者の健康データの収集、(iii) 教育、(iv) フィードバックという4つの重要な機能が挙げられている[15]。しかし、既存研究では食後高血糖を考慮して、実際に食事をする際の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。

2.3 本研究の位置付け

既存研究では、糖尿病の管理を目的としたシステムが多く、健常者を支援する手法はほとんど存在しない。また、SMBGデバイスの使用により、離散的な血糖値データを使用している点や患者への負担が大きい点、食事をする際に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。こうした問題点を踏まえて、著者らはリアルタイムに血糖値を測定しつつ、摂取予定の食事から食後高血糖を事前に予測し、各食品の推薦摂取量をフィードバックすることで、血糖値のコントロールを可能とする自己管理システムを提案してきた[5]。しかし、高血糖領域の予測精度が不十分であることや、摂食速度や順番といった食べ方の影響が考慮されていない。本稿では、提案システムの実現

に向けた第一段階として、血糖値予測モデルの精度向上と摂食速度・順番のデータ分析に焦点を当てる。データ分析により考慮すべき特徴量を明確にし、食後高血糖を予測する血糖値予測モデルの精度向上を目指す。また、指定した食事で摂食速度を変更した際の血糖値への影響についても報告する。

3. 提案手法

3.1 システム構成

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システムの実現を目指し、リアルタイムに血糖値を測定しつつ、摂取予定の食事から食後高血糖を予測し、各食品の推奨摂取量をフィードバックすることで、血糖値をコントロールすることを目的としている [5]。図 1 に提案する自己管理システムの全体像を示す。

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・量の選定を行う。

3.2 データ収集

Woldaregay らの研究 [16] では、血糖値には食事の摂取、BMI、ストレス、炭水化物摂取量、睡眠時間、身体活動、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 [5] を用いて、血糖値、食事情報（食事画像や食事の開始・終了時刻）、睡眠情報（就寝および起床時間）、およびユーザ情報（身長・体重）を収集する。

血糖値データの収集において、CGM デバイスである FreeStyle リブレ^{*1}およびセンサデータを Bluetooth を介してスマートフォンに送信可能な BluCon^{*2}を用いて継続的に取得する。FreeStyle リブレと BluCon を腕に装着した時の様子を図 2 に示す。FreeStyle リブレは 24 時間連続で 2 週間の血糖値データを収集することができる。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 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が可能である。

3.3 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抽出した特徴量を用いて、食事 2 時間後の血糖値を予測するモデルを構築する。先行研究 [5] では、食品ごとの血糖値の上昇度合いを示す指数である GI 値や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 値を特徴量として使用している。本研究では、これらの特徴量に加えて、食後数十分後の血糖値を予測し、その予測値を使用する。予測精度は、予測時間が長くなるほど困難となるため、より短時間の予測を行い、その値を特徴量として使用することで、疑似的に予測時間を短くすることを考える。本稿では、食事 30, 60, 90 分後の予測値を使用し、食事 2 時間後の血糖値を予測する手法を提案する。食事 30, 60, 90 分後の予測値を使用することで、実際には 2 時間後を予測するものの、疑似的に 30 分後を予測することとなる。

3.4 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糖尿病予備軍の指標となる食事 2 時間後の血糖値状態が 140 mg/dl 以上となると予測した場合、各食品の摂取量を減らすことで、血糖値の上昇を抑える。先行研究 [5] では、ユーザの嗜好を優先した欲張り法を採用している。この手法では、各食品に対して全ての値を足した場合に 100 となる嗜好度が与えられており、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% ずつ減らしている。ユーザの各食品に対する嗜好を考慮することで、推薦の受入率向上を図る。

3.5 推奨摂取量のフィードバック

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スマートフォン上に可視化する。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。先行研究 [5] では、ナッジ手法を用いて、推薦量の結果とともに、「アプリ使用者の 86% は、この推奨摂取量に従っています。」といったメッセージを表示している。Caraban の研究によると [17]、ナッジ手法は 23 種類存在し、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ている。可視化する際は、データ収集に使用したアプリケーションを使用し、モバイルデバイスの利用を軸とすることで、ユーザの手軽な利用・参加を実現する。

4. 実験設計

4.1 実験概要

本研究では、血糖値予測モデルの構築のための実験（実験 1）と、摂食速度による血糖値への影響調査のための実験（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、食事情報をはじめとする血糖値に影響のあるデータを収集し、特徴量を抽出す

*1 <https://www.myfreestyle.jp/>

*2 <https://cgm.ambrosiasys.com/>

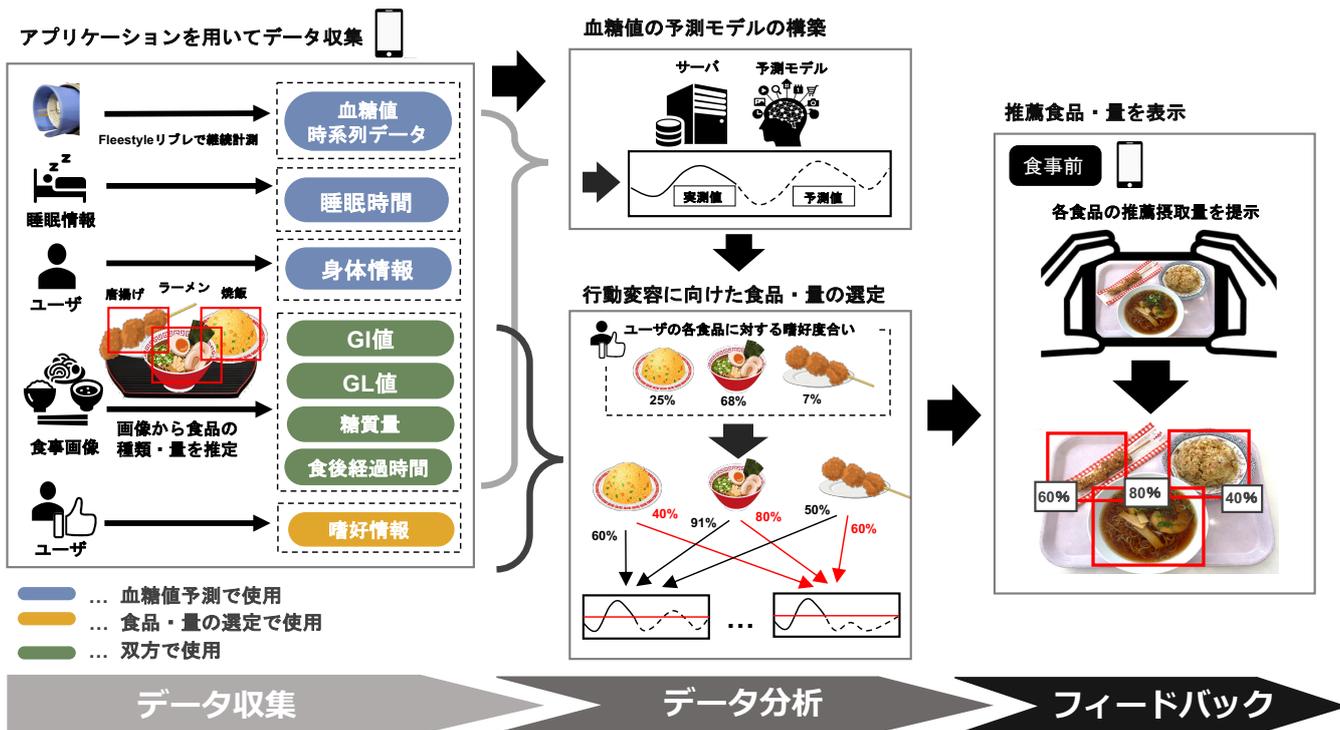


図 1 提案システムの概要



(a) リブレセンサ (b) センサ装着時

図 2 装着時の CGM デバイス

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)
食後 30 分ごとの予測値	各予測モデルが予測した値

る。抽出した特徴量を用いて個人ごとの血糖値予測モデルを構築し、モデルの精度を評価した。実験 2 では、非糖尿病患者である成人男性 3 人と成人女性 1 人を対象とし、4 日間同じ昼食で食事時間と順番を変更する実験を行った。各食事の血糖値上昇の違いから、摂食速度・順番による血糖値への影響を分析した。

表 2 各メニューの GI 値一覧

メニュー	GI 値
マカロニサラダ	71
コーンスープ	73
カレーライス (ジャガイモやにんじんを含む)	86
コロッケ	108

4.2 実験 1: 新たな特徴量を使用した血糖値予測モデルの評価

実験 1 の目的は、本稿の提案が予測精度の向上に効果があることを確認することである。本実験では、先行研究 [5] の実験で収集したデータを使用する。これまでの特徴量に加え、新たな特徴量として、食事 30, 60, 90 分後の予測値を使用し、2 時間後の血糖値を予測するモデルの精度を比較する。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。血糖値を予測する機械学習アルゴリズムは、回帰的な予測モデルの作成が可能な Random Forest で構築し、モデルの汎用性を RMSE と MAE で評価した。また、先行研究では、モデル評価の際に Hold-out 法を使用したが、本研究では、血糖値データが 15 分間隔で約 2 週間自動収集されることから、1 日ごとのデータはほとんど均等であるため、Leave-One-Day-Out 法を用いて交差検証を行う。

4.3 実験 2: 摂食速度・順番による血糖値への影響調査

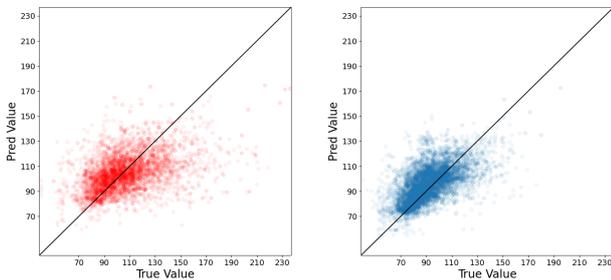
実験 2 の目的は、食事時間による血糖値上昇の影響を確認することである。本実験では、各被験者に FreeStyle リ

表 3 各被験者の予測モデルの評価

被験者	RMSE*	MAE*	RMSE**	MAE**
A	17.89	12.95	16.54 (-1.35)	12.06 (-0.89)
B	14.80	11.55	13.30 (-1.50)	10.49 (-1.06)
C	16.65	12.42	15.69 (-0.96)	11.70 (-0.72)
D	24.19	18.75	23.62 (-0.57)	18.75 (-0.0)
E	24.42	17.80	21.30 (-3.12)	16.35 (-1.45)
F	16.92	12.68	15.08 (-1.84)	11.10 (-1.58)
G	16.33	12.31	15.06 (-1.27)	10.96 (-1.35)
H	12.34	8.85	11.26 (-1.08)	7.98 (-0.87)
I	15.73	12.76	13.77 (-1.96)	10.81 (-1.95)
J	18.71	13.83	18.29 (-0.42)	13.35 (-0.48)

* 新しい特徴量を使用しない場合 [5]

** 新しい特徴量を使用した場合



(a) 食事開始から食事 2 時間後ま (b) 食事時間以外のテストデータでのテストデータ

図 3 全被験者の予測モデル評価

ブレを装着してもらい、リアルタイムな血糖値データを 2 週間収集してもらった。また、2 週間のデータ収集期間のうち、4 回の昼食について、指定した献立で食事してもらった。指定した献立と GI 値を表 2 に示す。献立の内容は、マカロニサラダ、コーンスープ、カレーライス、コロッケである。1 回目から 3 回目は食事の順番を指定せず、1 回目は 10 分、2 回目は 20 分、3 回目は 30 分と時間を変更して食事してもらった。4 回目は食事時間を 20 分に設定し、食事の順番を GI 値の低いものから食べてもらうように指定した。また、1 回目から 3 回目は食事時間による血糖値への影響調査が目的のため、食事の順番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うようにしている。

5. 実験結果

5.1 実験 1 の結果

新たな特徴量を加え、収集したデータを基に構築した血糖値予測モデルによる結果を表 3 と図 3 に示す。表 3 では、先行研究 [5] で用いた特徴量を使用したモデルと新たな特徴量を使用したモデルの精度評価とその差分を括弧内に示している。各被験者の予測モデルを評価した結果、全被験者において、新たな特徴量を使用した予測モデルの方が使用していない場合と比較して精度が向上した。特に被験者 H のモデル精度が最も高く、RMSE は 11.26, MAE

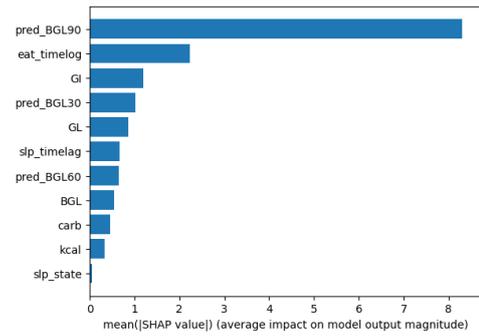
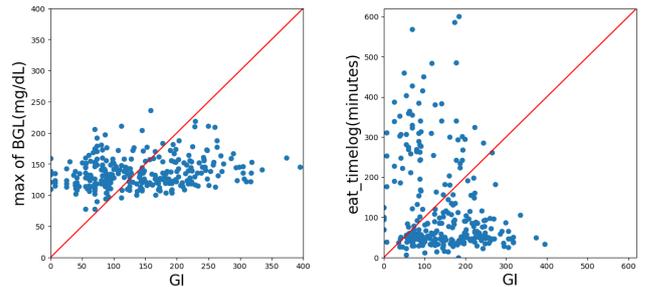


図 4 特徴量の重要度指標:SHAP 値



(a) GI 値に対する BGL 最高値 (b) GI 値に対する BGL 最高値に至るまでの時間

図 5 GI 値における各食事の最高血糖値と到達時間の散布図

は 7.98 となった。図 3 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ている。血糖値予測モデルの予測値と実測値に相関が見られたが、図 3(a) では、特に高血糖領域である 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。

構築した血糖値予測モデルの評価をもとに、収集したデータを分析した結果を図 4, 5, 6 に示す。図 4 では、モデル精度が最も高い被験者 H の各特徴量の寄与度を SHAP 値で示した。特徴量の寄与度は上から順に、食事 90 分後の予測値、食事経過時間、GI 値、食事 30 分後の予測値、GI 値、睡眠時間、食事 60 分後の予測値、食事開始時の血糖値、糖質量、カロリーである。この図より、食事 90 分後の予測値が予測モデルへの寄与度が大きいことがわかった。

図 5 は収集したデータから GI 値に対する各食事の血糖値の最高値と、GI 値に対する各食事の血糖値が最高値に至るまでの時間を散布図で示している。図 5(a) では、GI 値に関わらず各食事の血糖値の最高時が 100~250 mg/dl に収まっている。また、図 5(b) では、同じ GI 値の食事に対して血糖値が最高値に至るまでの時間に大きな振り幅があることを確認した。

図 6 に、食事の品目と血糖値の上昇に関連性のある時系列データを示す。一般的に食後高血糖の値である 140 mg/dl を赤色の点線、低血糖の値である 70 mg/dl を黒線の点線、被験者が食事をした時間を緑線で示した。白米や食パン、

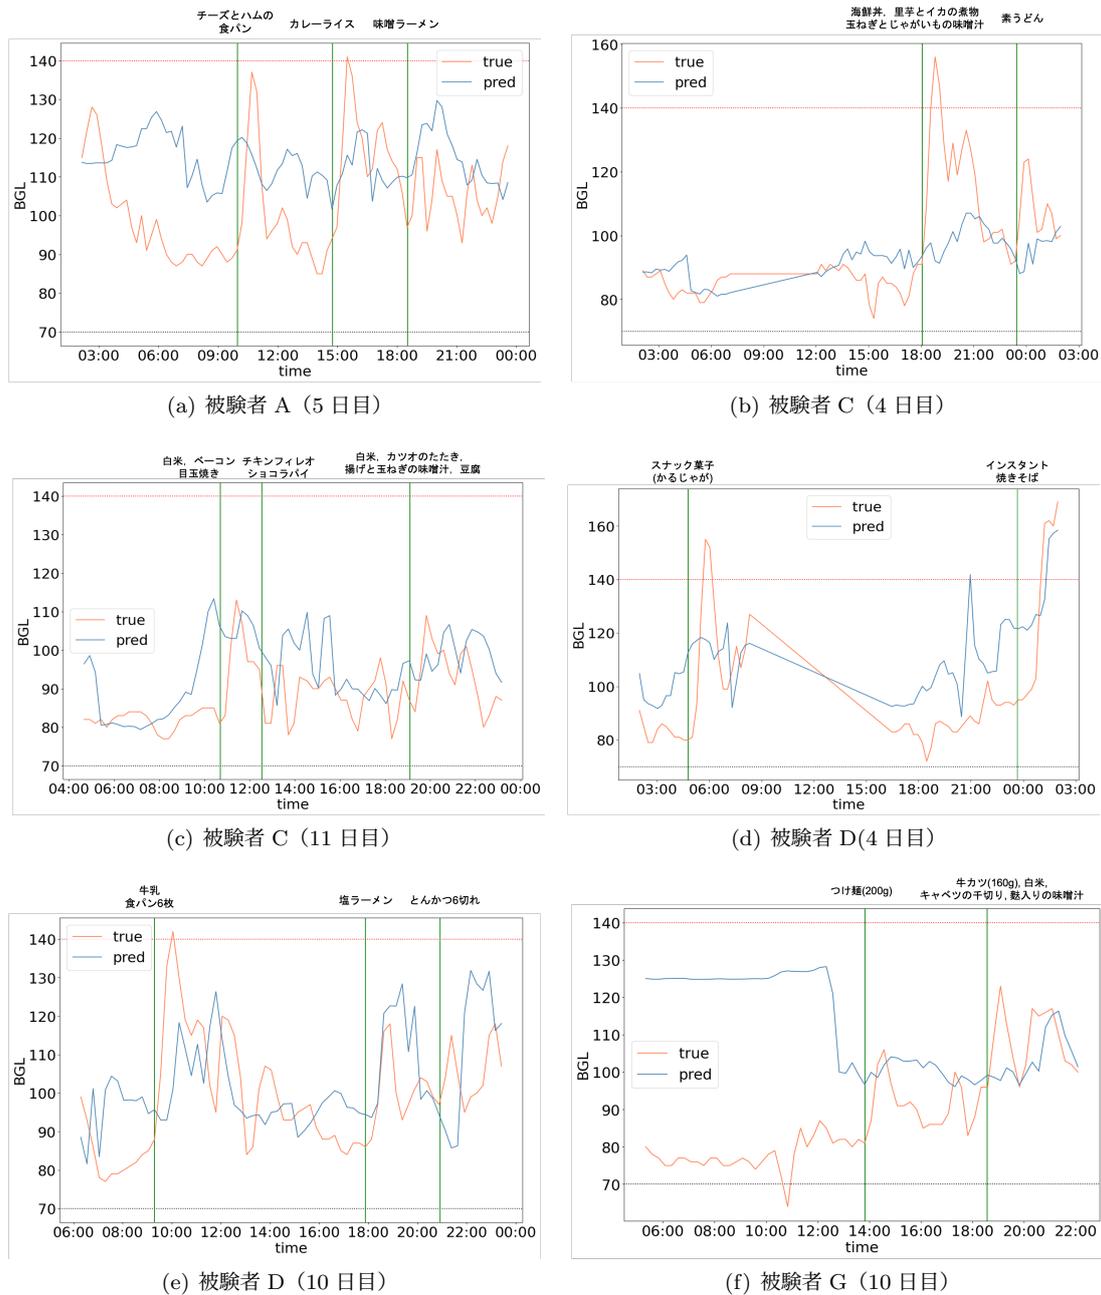


図 6 被験者 A, C, D, G の 1 日の血糖値時系列データ

じゃがいも、インスタントラーメンといった高 GI 食品を摂取した場合、高血糖領域である 140 mg/dl を超えている場合が殆どであり、予測モデルは実測値よりも低く予測していることが、このグラフからも確認した。また、同じ炭水化物でも麺類は中 GI 値食品であるため、血糖値も 140 mg/dl を超えることが少ないという結果が得られた。

5.2 実験 2 の結果

実験 2 の結果を図 7 に示す。折れ線グラフにおいて、赤線は食事時間が 10 分、黄色線は 20 分、緑線は 30 分、青線は食事時間を 20 分にし、食事の順番を GI 値が低い順番に食べた場合の血糖値の変化を明示している。また、実験 1

の結果同様に、一般的に食後高血糖の値である 140 mg/dl と低血糖の値である 70 mg/dl を黒線の点線で示した。

食事時間 10 分の時は、他の食事時間と比較して、食後高血糖の発生や一度上昇した血糖値が下がらない被験者が見られた。食事時間 20 分と 30 分を比較すると、30 分の方が血糖値の上昇は遅いが、あまり大きな差は見られなかった。

4 回目の食事の順番による血糖値は、食事時間が同じ 2 回目と比較して、血糖値の上昇が早い被験者もいれば、血糖値が上がらない被験者もいる結果となり、特徴的な傾向は確認されなかった。

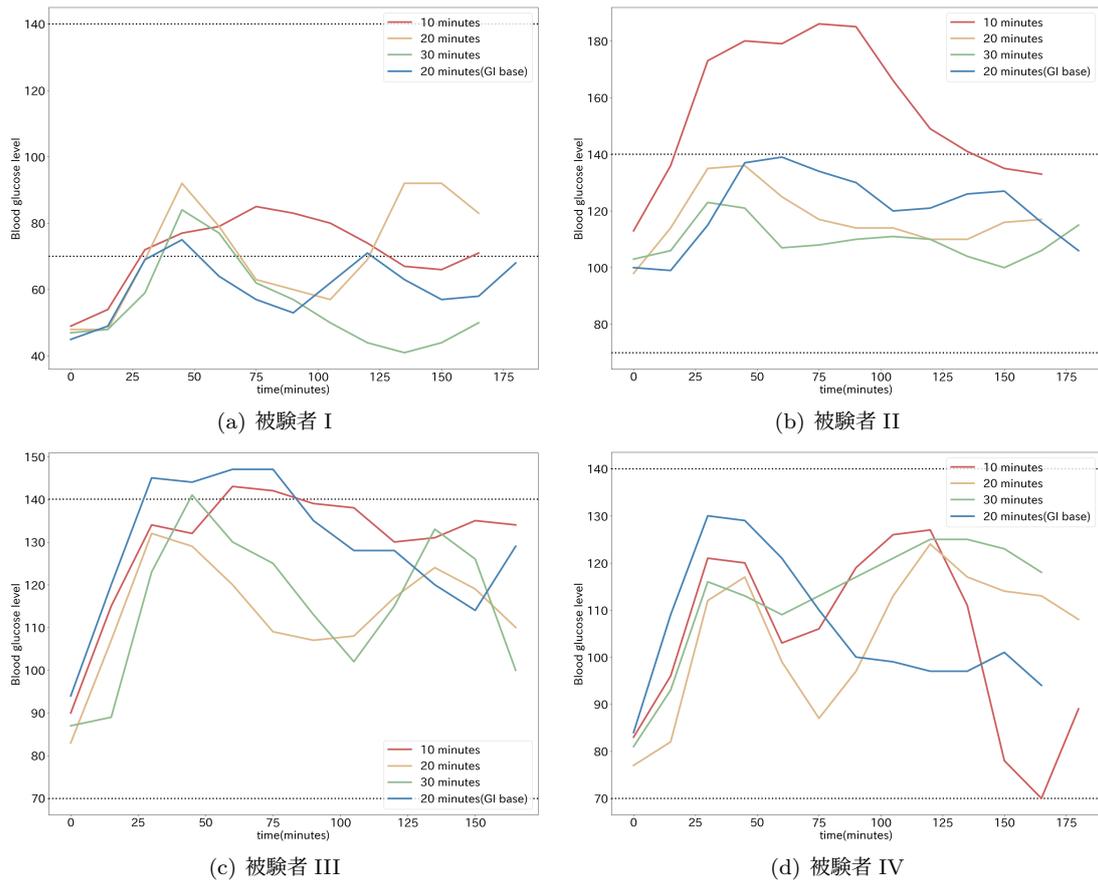


図 7 各被験者における各昼食摂取後の血糖値の時系列データ

5.3 考察

図 6 の実験 1 の結果より、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。特に被験者 A,C,D が白米や食パンといった高 GI 食品を摂取した場合に大きく外していることがわかる。図 5(a) より、どの GI 値に関わらず血糖値の分散が変わらない要因として、糖質量や GI 値が各食品の総和としているため、各食品の特徴を考慮することができていないことが挙げられる。そのため、高 GI 食品を摂取していると判断できる特徴量を使用することが必要である。また、図 6(c) や図 6(f) のように、被験者 C,G が白米といった高い GI 値食品を摂取しているにも関わらず、高血糖領域に達しない日があった。要因として、これらの被験者はこの日、普段よりも過度な運動をしていたため、急峻な血糖値上昇は見られなかったと考えられる。この結果は、Woldaregay らの研究 [16] で、身体活動は血糖値に影響を与えると述べられている通り、本実験でも同様の結果が得られた。そのため、高 GI 食品を摂取していると判断できる特徴量や身体活動の特徴量を新たに考慮することで、よりシステムへの利用可能な精度に向上させることができる。

図 7 の実験 2 の結果より、食事時間 10 分の時は、若年かつ非糖尿被験者であっても食後高血糖の発生や、一度上昇した血糖値が下がらない傾向を確認した。また、食事時

間 20 分と 30 分では大きな差が見られなかったことから、過度な摂食速度でなければ、血糖値には大きく影響しないことが分かった。同じ食事内容であっても、摂取速度が極端に早い場合（10 分の場合）、血糖値が通常よりも上昇する可能性があるため、食後高血糖を発生させないためには、食事の推薦摂取量だけでなく、摂食速度を抑えるフィードバックをシステムに組み込む必要があることがわかった。

また、両実験における Freestyle リブレの誤差による実験結果への影響について、Freestyle リブレは血液中ではなく、間質液のグルコース濃度を測定するため、誤差が生じる可能性がある。しかし、血液中と間質液のグルコース濃度には相関があるため、実験やシステムへの応用は十分可能であると考えられる [18]。

6. おわりに

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、血糖値のコントロールを可能とする自己管理システムの実現のために、データ分析に焦点を当てた。血糖値予測モデルを構築する際に、先行研究では考慮されてこなかった、食事 2 時間後までの予測値を新たな特徴量として使用することで、予測の精度が向上した。また、データ分析の結果、摂取した品目の特徴や身体活動を考慮することで、さらに予測精度が向上する可能性を示

した。摂食速度による血糖値への影響では、早い摂食は若年層でも食後高血糖の発生や、一度上昇した血糖値が下がらない傾向が見られた。

今後は、被験者の規模を拡大し、約 20 名の新たな被験者を対象に、摂取した品目の特徴、身体活動、摂食速度の特徴を加えたデータ収集を行い、更なる予測精度向上を目指す。また、食事におけるフィードバックによる行動変容が目標であるため、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ある。また、本研究の実験に、foo.log 株式会社提供の API を使用している。ここに記して謝意を示す。

参考文献

- [1] Pouya Saeedi, Inga Petersohn, Paraskevi Salpea, Belma Malanda, Suvi Karuranga, Nigel Unwin, Stephen Colagiuri, Leonor Guariguata, Ayesha A Motala, Katherine Ogurtsova, et al. Global and regional diabetes prevalence estimates for 2019 and projections for 2030 and 2045: Results from the international diabetes federation diabetes atlas. *Diabetes research and clinical practice*, Vol. 157, p. 107843, 2019.
- [2] Moien Abdul Basith Khan, Muhammad Jawad Hashim, Jeffrey Kwan King, Romona Devi Govender, Halla Mustafa, and Juma Al Kaabi. Epidemiology of type 2 diabetes—global burden of disease and forecasted trends. *Journal of epidemiology and global health*, Vol. 10, No. 1, p. 107, 2020.
- [3] Shafat Lone, Kouser Lone, Saika Khan, and Rafiq Ahmed Pampori. Assessment of metabolic syndrome in kashmiri population with type 2 diabetes employing the standard criteria's given by who, nceptap iii and idf. *Journal of epidemiology and global health*, Vol. 7, No. 4, pp. 235–239, 2017.
- [4] 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. (Accessed on 2023-07-23).
- [5] 道浦菜々子, 松田裕貴, 諏訪博彦, 安本慶一. 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. 研究報告センサネットワークとモバイルインテリジェンス (SeMI), Vol. 2023, No. 29, pp. 1–6, 2023.
- [6] Rei Otsuka, Koji Tamakoshi, Hiroshi Yatsuya, Keiko Wada, Kunihiko Matsushita, Pei OuYang, Yo Hotta, Seiko Takefuji, Hirotsugu Mitsuhashi, Kaichiro Sugiura, et al. Eating fast leads to insulin resistance: findings in middle-aged japanese men and women. *Preventive medicine*, Vol. 46, No. 2, pp. 154–159, 2008.
- [7] Anandghan Waghmare, Farshid Salemi Parizi, Jason Hoffman, Yuntao Wang, Matthew Thompson, and Shwetak Patel. Glucoscreen: A smartphone-based readerless glucose test strip for prediabetes screening. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 7, No. 1, pp. 1–20, 2023.
- [8] Ganjar Alfian, Muhammad Syafrudin, Muhammad Fazal Ijaz, M Alex Syaekhoni, Norma Latif Fitriyani, and Jongtae 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.
- [9] Andrés-Marcelo Calle-Bustos, M-Carmen Juan, Inmaculada García-García, and Francisco Abad. An augmented reality game to support therapeutic education for children with diabetes. *PLoS ONE*, Vol. 12, No. 9, p. e0184645, 2017.
- [10] Pooja M Desai, Elliot G Mitchell, Maria L Hwang, Matthew E Levine, David J Albers, and Lena Mamykina. Personal health oracle: Explorations of personalized predictions in diabetes self-management. In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, pp. 1–13, 2019.
- [11] Hugh Byrne, Brian Caulfield, Madeleine Lowery, Chris J Thompson, Diarmuid Smith, Margaret Griffin, and Giuseppe De Vito. Is it feasible to combine non-standard exercise prescriptions with novel smartphone adaptive coaching systems to improve physical activity and health related outcomes in type 2 diabetes mellitus? In *Proceedings of the 12th EAI International Conference on Pervasive Computing Technologies for Healthcare*, pp. 356–359, 2018.
- [12] Satoko Yamaguchi, Kayo Waki, Yasuhito Nannya, Masaomi Nangaku, Takashi Kadowaki, Kazuhiko Ohe, et al. Usage patterns of gluconote, a self-management smartphone app, based on researchkit for patients with type 2 diabetes and prediabetes. *JMIR mHealth and uHealth*, Vol. 7, No. 4, p. e13204, 2019.
- [13] Jakob E Bardram, Claus Cramer-Petersen, Alban Maxhuni, Mads VS Christensen, Per Bækgaard, Dan R Persson, Nanna Lind, Merete B Christensen, Kirsten Nørgaard, Jayden Khakurel, et al. Diafocus: A personal health technology for adaptive assessment in long-term management of type 2 diabetes. *ACM Transactions on Computing for Healthcare*, Vol. 4, No. 2, pp. 1–43, 2023.
- [14] Shane Joachim, Abdur Rahim Mohammad Forkan, Prem Prakash Jayaraman, Ahsan Morshed, and Nilmini Wickramasinghe. A Nudge-Inspired AI-Driven Health Platform for Self-Management of Diabetes. *Sensors*, Vol. 22, No. 12, p. 4620, 2022.
- [15] Deborah A Greenwood, Perry M Gee, Kathy J Fatkin, and Malinda Peoples. A systematic review of reviews evaluating technology-enabled diabetes self-management education and support. *Journal of diabetes science and technology*, Vol. 11, No. 5, pp. 1015–1027, 2017.
- [16] Ashenafi Zebene Woldaregay, Eirik Årsand, Ståle Walderhaug, David Albers, Lena Mamykina, Taxiarchis Botsis, and Gunnar 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.
- [17] Ana Caraban, Evangelos Karapanos, Daniel Gonçalves, and Pedro Campos. 23 ways to nudge: A review of technology-mediated nudging in human-computer interaction. In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, pp. 1–15, 2019.
- [18] Kerstin Rebrin and Garry M Steil. Can interstitial glucose assessment replace blood glucose measurements? *Diabetes technology & therapeutics*, Vol. 2, No. 3, pp. 461–472, 2000.