

血糖値コントロールシステムの実現に向けたデータ分析

玉置 理沙¹ 藤本 まなと¹ 諏訪 博彦^{1,2} 安本 慶一¹

概要: 近年、糖尿病患者のための血糖値コントロール支援が盛んに行われている。しかし、糖尿病患者ではない成人を支援する手法はほとんど存在しない。血糖値の高すぎるピークや長時間に及ぶ食後高血糖は、2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り、糖尿病患者と診断される前の未病の段階で予防することが重要である。そのためには、血糖値コントロールが必要であり、リアルタイムで血糖値を把握しながら血糖値を予測できることが望ましい。本研究では、摂取予定の食事を撮影すると、事前に予測血糖値を提示し、また、血糖値の高いピークが生じる可能性が高い場合には摂取して良い食べ物と摂取すべきでない食べ物を提示することで、血糖値をコントロールするシステムを提案する。本研究では、血糖値コントロールシステムへの実現に向けた第一段階として、血糖値推定モデルの作成と検証を目的としたデータ分析を行った。具体的には、4名の被験者から血糖値推定を目的とし、食事のGI値や前回の食事時間からの経過時間、睡眠時間のデータを収集・特徴量を抽出し、各被験者に対する血糖値推定モデルをランダムフォレストを使って構築した。その結果、最も精度の高い被験者のRMSE（二乗平均平方根誤差）は10.09、 R^2 （決定関数）は0.82、MAE（平均絶対誤差）は6.00であった。この結果から、提案システムの実現可能性が示された。

1. はじめに

近年、我が国では、生活習慣の欧米化に伴い、生活習慣に起因する疾患である2型糖尿病の有病率が高くなっている。2型糖尿病は、遺伝素因と環境因子が関与する多因子疾患であり、糖尿病になりやすい遺伝素因に、肥満、過食、運動不足、ストレスなどの環境因子が加わって発症に至り、日本人の糖尿病患者の90%以上を2型糖尿病が占めている。

2019年3月1日に厚生労働省から発表された「2017年患者調査の概況」によると、糖尿病の通院患者数は、2014年の前回調査と比較して、約12万人程度増加し、328.9万人となった[1]。2017年9月に発表された「平成28年国民健康・栄養調査」によると、「糖尿病を強く疑う者」は約1,000万人と、前回調査が行われた2012年から約50万人増加している[2]。「糖尿病の可能性を否定できない人」も約1,000万人に達し、糖尿病及び糖尿病予備軍を合わせると、日本国民の5人に1人がこれに該当することから、糖尿病の発症予防が必要不可欠といえる。

糖尿病になる前の段階である「糖尿病予備軍」において、食事から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、糖尿病判定において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病気のレベルまで上がらない。そのため、糖尿病予備軍や糖尿病初期の場合、診断から漏れてしまう可能性が非常に高い。

また、大塚らの研究[3]は、早い摂食速度は、血糖値を下げるインスリンの感受性を低下させ、糖尿病を引き起こす可能性があるとして指摘している。現在、食後2時間後の血糖値を把握するには、定期的に穿刺を行い血糖値を測定する方法があるが、極めて負担が大きい。穿刺の必要ない連続血糖値測定機器もあるが、食後2時間後の血糖値を把握するのみで、食後高血糖を避けられるわけではない。食後高血糖を回避するには、血糖値の把握のみならず、血糖値が過度に上昇しないような食事をする必要があり、そのためのコントロールシステムが必要である。

既存手法である杉田らの研究[4]では、食事・行動履歴から血糖値と空腹度を推定している。しかしながら、この研究では、推定モデルの構築において、従来の穿刺型の血糖値測定器を用いるため、定期的な穿刺により、離散的なデータしか取得できないという点と、食事情報をカロリーのみで考慮している点で血糖値の正確な推定が難しい。さらに、Poojaらの研究[5]では、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

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

² 理化学研究所
RIKEN, Center for Advanced Intelligence Project AIP

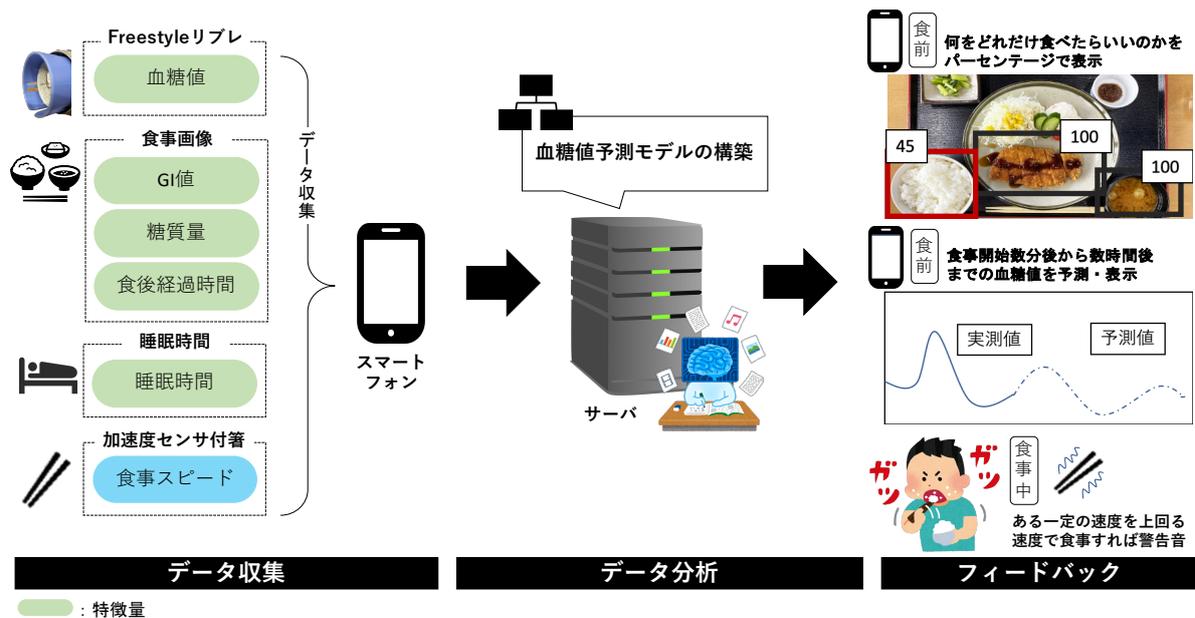


図1 提案システムの全体像

的とするアプリケーションを開発している。しかし問題点として、予測モデルの精度が不明であるため、実際の値とかけ離れている可能性がある点や、食事の栄養の手入力によりユーザーが調べる必要があるという点がある。

このような問題を解決するため、我々は、連続的に血糖値データの収集が可能な血糖値測定専用センサである Freestyle リブレを一定期間（約2週間）にわたって非糖尿病患者である被験者に装着してもらい、食事履歴を記録したところ、食事のカロリーに比べてGI値（Glycemic Index:食品そのものの血糖値の上昇度合いを示す。）の方が血糖値に影響を及ぼしていることが判明した [6]。本研究では、リアルタイムで血糖値を測定し、最終的にユーザーの摂取した食事履歴と血糖値データから、被験者の血糖値を数分後から食後数時間後まで予測・提示し、高血糖を避けるために摂取すべきでない食品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システムの開発を行うことを目標とする。

具体的には、図1に示すように、24時間連続で血糖値データを収集できる Freestyle リブレを使用し、被験者から血糖値を収集すると共に、スマートフォンを用いて食事を撮影する。その後、アプリケーション上で食事の撮影画像から自動的にGI値や糖質量を抽出し、前回の食事から経過した時間、血糖値データ、睡眠時間に関するデータと一緒にサーバにアップロードする。最後に、それらデータから抽出した特徴量から構築した回帰予測モデルを用いて血糖値を予測することで、食前に食後数分後から数時間後までの予測血糖値を表示する。予測血糖値の最高値が140 mg/dLといった高い数値を上回ると予測した場合、食事予定のメニューの中から高血糖が見込まれる食事の量を減ら

すよう提示する（図1では、おかずと味噌汁は100%食べても良いが、ごはんは45%に減らすべきであることが提示されている）。また、食事中に加速度センサ搭載の箸を使用することで摂食速度を検知し、ある一定の速度を上回れば食事中に警告音を発する等を行うことで、ユーザーに血糖値の急激な上昇を抑えるよう促すような工夫も行う。

本稿では、上記で述べたシステムの実現に向けた第一段階として、データ分析に焦点を当て、血糖値推定モデル構築するための実験を行った。実験の目的は、収集するデータ項目から実際にシステムに利用できる精度を持つ血糖値推定モデルを構築できるかを検証することである。実験では、4名の被験者から血糖値を推定するため、食事に含まれるGI値、前回の食事時間からの経過した時間、睡眠時間のデータを収集し、これらの特徴量として各被験者に対する推定モデル作成をランダムフォレストを用いて試み、提案システムに利用可能なモデルであるかを検証した。その結果、被験者DのRMSEが10.09、 R^2 が0.82、MAEが6.00となり、提案システムに利用可能な血糖値推定モデルの構築が可能であることが示唆された。

2. 関連研究

2.1 食事・行動履歴に基づく空腹度推定

杉田らの研究 [4] では、単一の被験者に対して約一週間穿刺型の血糖値測定器を用いて定期的に測り、主観的な空腹度と関連付け、食事・行動履歴をもとに血糖値を予測するモデルを作成することで空腹度を予測する手法を提案している。単一被験者を対象としたこの実験では、食事・行動情報の記録に合わせて1日に計4回の測定を行っている。計測した実際の血糖値をグラウンドトゥールースとし実験に

おけるパラメータとの比較を行っており、また、食事・行動情報の記録は記録シートを用意し適宜シート上に記入している。実験においては食事情報・行動情報の他に、計測時の空腹感の強さの5段階評価値し、摂取した食事のカロリーや、計測時の体調の良さの5段階評価値をパラメータとして取り入れている。しかし、この研究では、食事は考慮しているが食事の糖質量までは考慮していないため、血糖値の測定に一定の誤差が生じるといった問題がある。また、穿刺型の血糖値測定値を用いたことにより、血糖値測定のため、数時間ごとに穿刺が必要であり、被験者への負担が大きいといった問題もある。

2.2 BLE センサを使った糖尿病モニタリングシステム

Alfian らの研究 [7] では、BLE ベースのセンサデバイス、リアルタイムデータ処理、機械学習アルゴリズムを利用して、糖尿病患者の慢性的な状態を自己管理するためのヘルスケアモニタリングシステムを提案している。BLE 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、連続的に生成される大量のセンサデータを管理するため、リアルタイムデータ処理を利用している。この研究では、70 人の糖尿病患者からインスリン投与量、BG 測定値、食事摂取量、運動活動などのデータを収集し、糖尿病の分類と血糖値予測が行われた。分類にはランダムフォレスト、ナイーブベイズ、SVM、ロジスティック回帰、MLP が用いられ、予測には LSTM と線形回帰が用いられている。その結果、ランダムフォレスト、ナイーブベイズ、SVM、および、ロジスティック回帰で、それぞれ 73.046 %、76.6927 %、76.562 %、および 76.0417 % を示し、MLP が 77.083 % と最も高い精度となった。LSTM による血糖値予測では、得られた二乗平均平方根誤差 (RMSE) は 25.621 であり、線形回帰では RMSE が 44.069 であった。この研究では、血糖値測定機器として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な点が課題である。加えて、長期間における糖尿病モニタリングの際には負担が極めて高い点、さらには食事摂取量のみでは糖質量や GI 値といったといった血糖値への大きな影響を与える要素が考慮されていないため RMSE が低くない点も課題となる。

2.3 糖尿病自己管理のためのアプリケーション

Pooja らの研究 [5] 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。これを実現するために、GlucOracle は、ユーザに食事の写真とその内容のテキスト入力、さらに食前と食後 2 時間後の血糖値データを収集する。これらのデータを血糖値予測のための訓練データとして学習し、

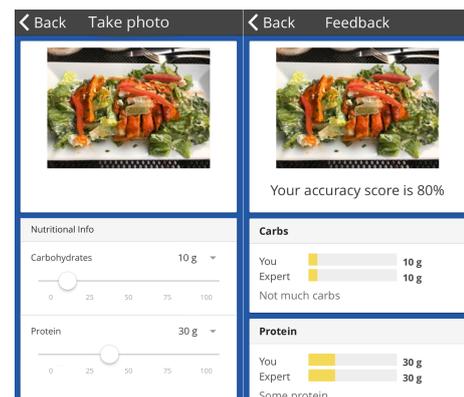


図 2 糖尿病自己管理のためのアプリケーション

データ同化により GlucOracle は食後 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。その後、ユーザは、食事を登録し直すことが可能であり、食事を追加あるいは削除する度に予測血糖値が更新される。また、アプリケーションに栄養素を入力することで、図 2 のような栄養評価を受けられる。しかし、この研究の問題点として、予測モデルの精度が不明であるため、実際の値とかけ離れている可能性がある点や、食事の栄養の手入力によりユーザが調べる必要があるという点が挙げられる。

2.4 本研究の位置付け

従来の研究では、糖尿病管理を目的とした血糖値のモニタリングシステムが主流であり、1) 穿刺性の器具の使用により離散的なデータしか得られない点、2) データ収集の際に食事の情報として食事時間とカロリーのみしか考慮されていないことにより予測モデルが高精度でない点、3) アプリケーション開発時に食事の栄養素の手入力が必要な点が問題点として挙げられる。モニタリングに止まらず、糖尿病の発症そのものを防ぐには、血糖値予測の精度を向上するだけでなく、血糖値をあげやすい食事を制限することで血糖値の上昇を防ぎ、コントロールするシステムが必要である。本研究では、このような血糖値コントロールシステムの開発を目標としており、特に本稿では、血糖値コントロールシステム実現に向けた第一段階として、データ分析に焦点を当てる。具体的には、4 名の被験者から食事情報や食事時の GI 値、前回の食事時間からの経過した時間、睡眠時間のデータを収集し、これらの特徴量、血糖値の推定を目的として各被験者に対する推定モデル作成を行い、システムに利用可能なモデルであるかを検証する。

3. 提案手法

本章では、提案するシステムの概要とその構成について述べる。

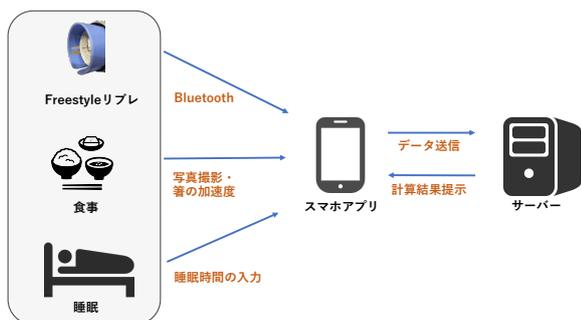


図 3 システム構成

3.1 提案システムの概要

本研究では、糖尿病でない成人の糖尿病発症を予防するため、スマートフォンを用いた新たな血糖値コントロールシステムを提案する。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。

要件 1 長期的にシステムを利用するため、定期的な痛み
の負担なく連続的に血糖値データを収集できること

要件 2 食事内容の GI 値を特徴量として予測モデルに組み込むことができること

要件 3 摂取すべき/すべきでない食品を食前に提示できること

これらの 3 つの要件を満たすことで、ユーザは負担を感じることなくシステムを利用できる。本研究では、Freestyle リブレを装着した状態で食事をし、スマートフォンのアプリケーションを利用して食事の摂取をコントロールすることで血糖値の過度な上昇を防ぐ。

3.2 システム構成

図 3 にシステム構成を示す。提案システムは、1) データ収集、2) アプリケーション、および、3) サーバから構成される。以下に、具体的に述べる。

3.2.1 データ収集

本システムでは、血糖値データおよび食事・睡眠データを収集する。

血糖値：本研究では、24 時間連続で血糖値のデータ収集が可能な Freestyle リブレを使用する。このセンサは 500 円玉サイズと小さく、装着時と装着間にほとんど痛みがない。その上耐水性もあるため、従来の穿刺型センサよりも負担なく、かつ生活に支障をきたすことなくデータ収集できる。通常、リーダをセンサに近づけて近距離無線通信 (NFC) で読み取り、リーダに表示する。提案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デバイスをセンサにかぶせることで測定値をスマートフォンに自動的に送信する。

食事・睡眠データ：Woldaregay らの研究 [8] によれば、血糖値には食事の摂取状況、ボディマスインデックス、ストレスレベル、炭水化物摂取量、睡眠時間、病気の有無、



(a) リブレセンサ (b) リブリーダ

図 4 Freestyle リブレ血糖値測定機器

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。提案システムでは、血糖値以外のデータ収集項目として、食事情報と睡眠時間を収集する。食事情報とは、具体的には最後の食事を摂取してからどのくらいの時間が経過したのか、糖質量、さらに食事そのものの血糖値のあげやすさを示す GI 値のことであり、考慮することで関連研究よりも血糖値予測モデルの精度向上を目指す。ここで、GI 値は以下の式で表される。

$$GI = \frac{AUC' \times 100}{AUC} \quad (1)$$

ここで、 AUC' は検査飼料を糖質 50g 摂取した時の血糖値曲線下面積を示し、 AUC は基準食を糖質 50g 分摂取した時の血糖値曲線下面積を示す。上記より、GI 値とは食品そのものの血糖値の上昇度合いを示す。一般的に、GI 値が高いほど血糖値が上昇しやすいとされているが、Foster らの研究 [9] によると、肉類、魚類、や芋類を除く野菜には、炭水化物はほとんど含まれないため、GI 値が極めて少ないとされている。食事情報の収集方法は、スマートフォンで食事の画像を撮影し、撮影したデータから 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。また加速度センサ搭載の箸を使用し加速度データとで箸の動作の連続性の有無により食事スピードの速さを検出する。最後に、睡眠時間をテキスト入力することで提案手法のデータ項目を収集する。

3.2.2 アプリケーション

本研究では、スマートフォンのアプリケーションを利用して食事の摂取をコントロールすることで、血糖値の過度な上昇を防ぐ機能を持つシステムを提案する。提案システムでは、収集した血糖値、食事情報、睡眠時間をスマートフォンを介してサーバにあげ、サーバ上で血糖値予測モデルを構築し、アプリケーションに返すことでユーザは食前に予測血糖値を知ることができる。また、ユーザの摂取予定の食事から予測される血糖値から高いピークが予想され、食後も高い血糖値が予測される場合には食事に含まれる高い GI 値の食品の摂取量を減らすようにフィードバックする。フィードバックの際には、どの食品をどのくらい食べたらいかを食品ごとにパーセント表示をすることで、図 1 の提案システム図のように摂取量を提示する。上記は食

前にフィードバックするが、食事時のフィードバックとしては、加速度センサ搭載の箸を使用した際に一定の速度を上回る速さで箸を動かした場合、もしくは、短期間で連続して箸を動かした場合には警告音が出るようにする。

3.2.3 サーバ

食事記録や睡眠時間をはじめとするデータをアプリケーションを介してサーバ上に保存する。アプリケーション上で食事の撮影画像から自動的に GI 値や糖質量を抽出し、前回の食事から経過した時間、血糖値データ、睡眠時間に関するデータと一緒にサーバにアップロードする。最後に、サーバ上で機械学習で血糖値予測モデルを作成し、アプリケーションに計算結果をフィードバックする。

3.3 血糖値予測手法

本節では、食事の開始前に予測血糖値を表示するための血糖値予測手法を提案する。本研究では、スマートフォンを通じて収集したデータをサーバにあげ、サーバ上で機械学習での血糖値予測モデルを構築する。また、機械学習の手法としては回帰的な予測モデルの作成が可能な Random Forest を用いる。Random Forest は、教師データセット内の学習データから回帰モデル作成するデータをランダムに選択することで、教師データのノイズの影響を受けにくい学習器である。ブートストラップによるデータの抽出、バギングにより作成された多数の決定木を組み合わせることで入力データから血糖値を予測する。本研究では、入力データから食事開始数分後から食後 2 時間後の血糖値の波形を予測し、食事開始前のタイミングでスマートフォン上に表示するシステムを提案するが、本稿では Random Forest を用いて血糖値推定モデルを作成し、RMSE, R^2 , MAE にてその精度を評価する。

4. 実験

4.1 実験概要

本研究では、倫理審査委員会での承認（承認番号 2019-M-2）のもと、血糖値予測モデルの構築にあたっての実験を行なった。本実験では、約 2 週間糖尿病患者でない成人 4 名（男性：3 名、女性：1 名）を対象に、血糖値データや食事情報、睡眠データを収集し、収集したデータが実際にシステムの実現に必要なデータであるのか、加えてシステム実現に向けた血糖値推定モデルの作成が可能かどうかを検証するため、個人ごとの血糖値の推定モデルを構築した。また、推定値と実測値との間の相関値と相対誤差の値を基準として、推定モデルの有用性を評価する。

4.2 実験方法

本稿では、血糖値推定を行った実験方法を述べる。データ分析のため、血糖値と食事時間、食事の内容、睡眠時間を収集し、これらから特徴量抽出し、血糖値推定モデルに組

表 1 機械学習における特徴量

特徴量	内容
食事後経過時間	食後の血糖値上昇を考慮
GI 値	食事に含まれている血糖値上昇指数を考慮
睡眠データ	就寝時間と睡眠時間

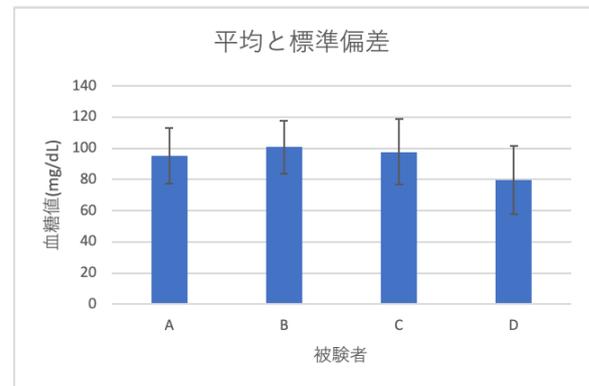


図 5 血糖値の平均値 [6]

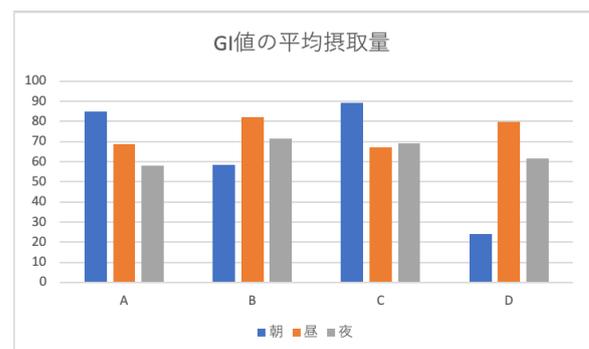


図 6 被験者の平均 GI 値摂取

み込んだ。具体的には、各被験者に Freestyle リブレを装着してもらい、食事時間と食事の内容、睡眠時間をエクセルファイルにテキスト入力してもらいながら、通常通りの生活を約 2 週間送ってもらった。Freestyle リブレは、2 週間 24 時間連続でデータ収集が可能であり、センサ装着間 15 分単位で血糖値が自動収集される。また、記録してもらった食事情報に含まれる食事内容をシドニー大学の Search for the Glycemic Index[10] を用いて推定 GI 値に変換した。本実験では、食事に含まれる各食品の最高 GI 値をその食事の GI 値とみなした。収集したデータから、食後経過時間、GI 値、睡眠時間を特徴量として抽出し、各被験者に対する血糖値推定モデルを構築した。表 1 に、使用した特徴量一覧に示す。本実験では、データセット中の食事情報として GI 値を考慮し、糖質量は考慮していない。GI 値は、血糖値の上昇指数であり、GI 値が特徴量として有効であるかを確認するため、本実験では、糖質量を考慮しないデータセットを作成した。実験で収集した 2 週間分の血糖値データを推定した結果を次節に示す。

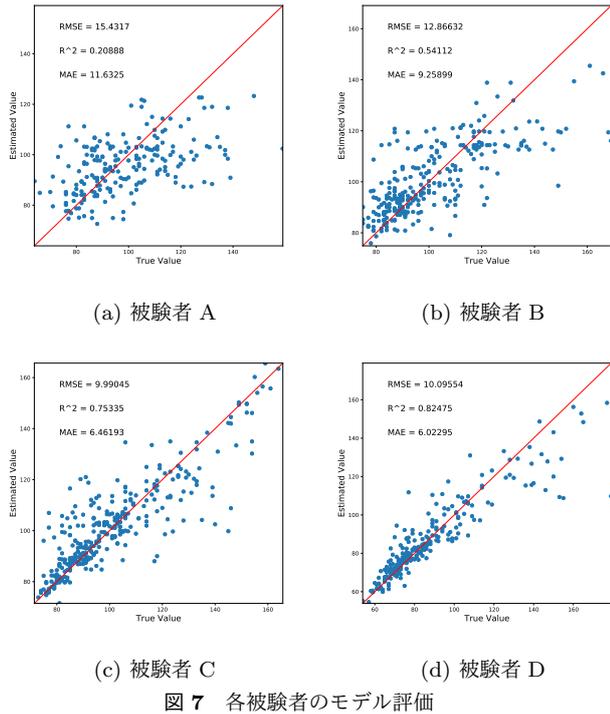


図 7 各被験者のモデル評価

4.3 結果

本実験で測定したデータと、収集したデータを基に構築した血糖値推定モデルによる結果を図 5 から図 11 に示す。図 5 に、各被験者の血糖値の平均値と標準偏差値を示す。血糖値の平均については、被験者 B が最も高く、標準偏差については、被験者 D が最も大きい。図 6 に被験者の摂取した食事の平均 GI 値を示す。被験者 A から C は、血糖値の平均値に大きな差はみられなかったが、実際の食生活には差が見られ、朝食に GI 値の高い食品を摂取する被験者や昼食に GI 値の高い食品を摂取する被験者が見られた。図 7 に、構築した各被験者のモデルに対する評価を示す。また、図 8 から図 11 に、約 2 週間測定した血糖値の実際のデータと血糖値推定モデルによる結果を示す。ここでは、一般的に食後高血糖時の値である 140 mg/dL を赤線、低血糖時の 70mg/dL を黒線で示すことにより、実験期間中の血糖値の変化を明示した。各被験者の血糖値データより、被験者全員が食後一時的に 140mg/dL を超えているという結果が得られた。また、GI 値の平均摂取値が最も高かった被験者 C が最も血糖値が 140 mg/dL を超える頻度が高いことがわかった。また、図 7 には構築したモデルの RMSE（二乗平均平方根誤差）と R^2 （決定係数）、MAE（平均絶対誤差）を示している。これらは、以下の数式で計算される。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^n (\hat{y}_i - y_i)^2} \quad (2)$$

表 2 推定モデルの評価

	A	B	C	D
RMSE	15.41	12.84	10	10.09
R^2	0.21	0.54	0.75	0.82
MAE	11.64	9.232	6.44	6.00

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

ここで、 n は全予測対象値、 \hat{y} は推定値、 y は実測値を示している。表 2 に、これらを計算した結果をまとめた。モデルを評価した結果、被験者 D のモデル精度が最も高い結果となった。

4.4 考察

図 5 より、平均の差はほとんど見られなかったが、図 6 と比較したところ、血糖値の平均値と GI 値の平均にある程度の相関が見られた。最も平均値が低い被験者 D は、実験期間中の GI 値の平均摂取量も被験者の中で最も低い結果となった。また、本実験では被験者が少なく、平均の差に性差が生じるのか十分に検討できなかったため、今後は女性の被験者を増やし、統計的検定手法を用いて調べる必要がある。本実験では、4 人の被験者からデータを収集し、血糖値推定モデルを構築したが、被験者 A と B からは睡眠時間のデータが得られなかった。そのため、4 人の被験者の中で上記の 2 名が最も RMSE が大きく、 R^2 が低い結果となった。また、被験者 C と D のモデルの評価より、これらの結果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。図 7 より、各被験者の血糖値推定モデルの 120mg/dL から 140mg/dl の範囲の推定血糖値と実測値との相関が弱いようにみえるが、この原因として、食品の GI 値換算に原因があると考えられる。GI 値換算の際に使用したシドニー大学の Search for the Glycemic Index[10] には和食に関する情報が少なく、麺類などの詳細な分類がされていないため、被験者が摂取した食事の GI 値が正確に反映されていないという点が挙げられる。本実験では、血糖値は自動的に 2 週間分収集できるが、その他のデータは手入力で行われたため、被験者ごとのデータ収集数に差が生じた。血糖値は食事と密接な関係にあり、通常、食事終了から約 1 時間にピークを迎えるという特徴がある。そのため、食事時間や間食時間をはじめとする詳細な食事情報と睡眠データ数不足により被験者ごとのモデルの精度に大幅な差が生じたと考えられる。したがって、提案システムのように、撮影した画像から自動的に GI 値を抽出し、各食事の撮影した時間の間隔を特徴量として組み込むことで、被験者のデータ入力の負担を極限まで減らすシステムが必

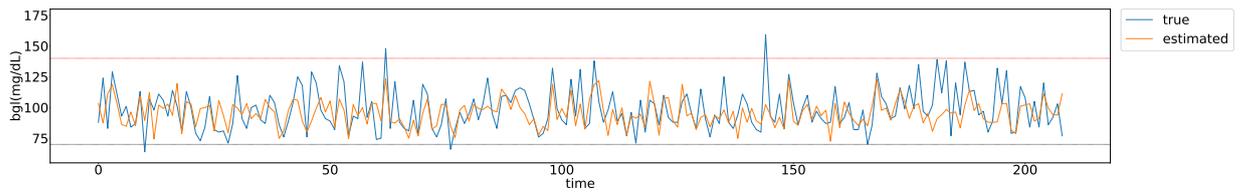


図 8 被験者 A の血糖値データと推定データ

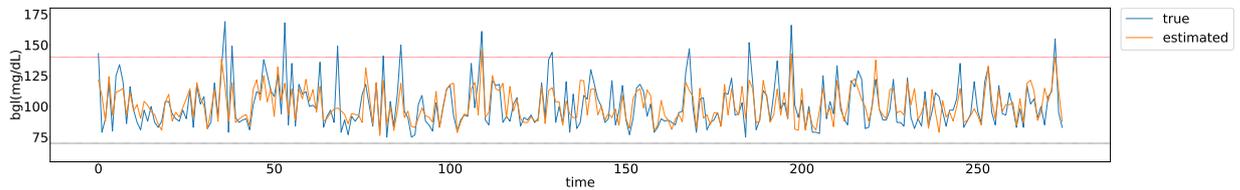


図 9 被験者 B の血糖値データと推定データ

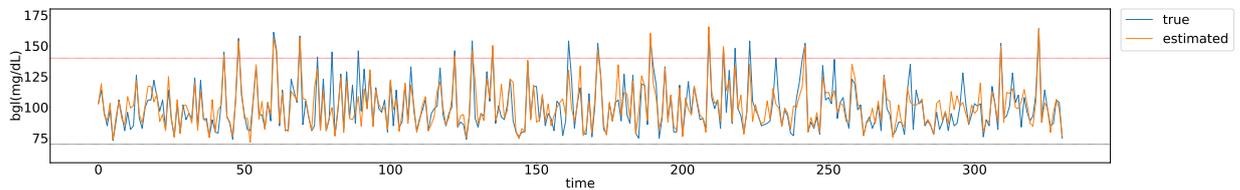


図 10 被験者 C の血糖値データと推定データ

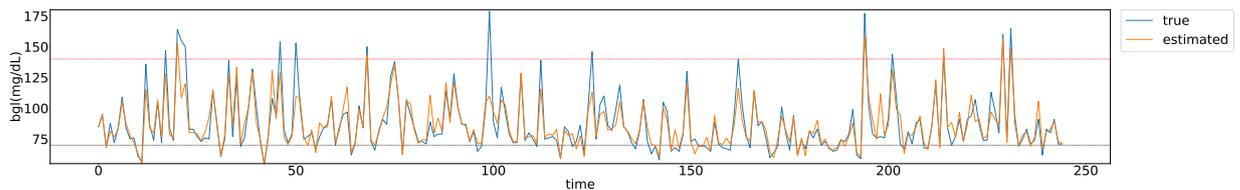


図 11 被験者 D の血糖値データと推定データ

要不可欠であることがわかった。

4.5 今後の課題

本実験では、被験者が4名で個人ごとの血糖値推定モデルを作成した。今後身体的特徴別、または、性別ごとの予測モデル作成が可能であることを検証するため、被験者の性別をある程度偏りなく、20名程度の新たな被験者を募集する予定である。また、予測モデルの精度向上のため、新たなデータ収集が必要であり、その際にはWEB APIを介して食事情報からGI値の抽出が自動的に行われ、入力負担の少ないインターフェースを用意するとともに、糖尿病ではない成人が血糖値をコントロールするためのシステムの実現を目指す予定である。

5. まとめ

生活習慣病の一種とされる糖尿病の予備軍は1000万人程度おり、このような社会問題を解決するため、本研究では現段階で健康な成人が糖尿病予備軍とならないための血

糖値コントロールシステムを提案した。本稿では、一般に食事の摂取状況、ボディマスインデックス、ストレスレベル、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、アレルギーなどが血糖値に影響を与える要因とされるなか、血糖値、食事情報と睡眠時間を収集しデータ分析した。推定モデル作成の際に食事情報として関連研究で考慮されていなかったGI値を特徴量として追加したところ、ある程度の相関が得られ、システムへの応用の可能性を示した。また、頻繁に高い血糖値のピークを迎える被験者も見られたことから血糖値をコントロールするシステムは有用性が高いといえる。今後は20名程度の新たな被験者を募集し、モデルの精度向上のため、糖質量をはじめとする新たなデータ収集を入力負担の少ないインターフェースを通じて行う予定である。これにより、糖尿病ではない成人が血糖値をコントロールするためのシステムの実現を目指す。

謝辞 本研究の一部は、科研費基盤研究(B)(No.20H04177)の助成によって行った。

参考文献

- [1] 厚生労働省. 2017 年患者調査の概況.
- [2] 厚生労働省. 平成 28 年国民健康・栄養調査.
- [3] Rei Otsuka, Koji Tamakoshi, Hiroshi Yatsuya, Keiko Wada, Kunihiko Matsushita, Pei OuYang, Yo Hotta, Seiko Takefuji, Hirotsugu Mitsuhashi, Kaichiro Sugiura, Satoshi Sasaki, John G. Kral, and Hideaki Toyoshima. Eating fast leads to insulin resistance: Findings in middle-aged japanese men and women. *Preventive Medicine*, Vol. 46, No. 2, pp. 154 – 159, 2008.
- [4] 杉田敢, 諏訪博彦, 荒川豊, 安本慶一. 食事・行動履歴に基づく非侵襲的空腹度推定手法. 2015 年度情報処理学会関西支部支部大会講演論文集, pp. 1–8, 2015.
- [5] 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.
- [6] 玉置理沙, 藤本まなと, 諏訪博彦, 安本慶一. 糖尿病予防のための血糖値コントロールに向けた予測モデルの開発. 2019 年度社会情報学シンポジウム講演論文集, pp. 1–6, 2019.
- [7] 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.
- [8] 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.
- [9] Thomas MS Wolever, David JA Jenkins, Alexandra L Jenkins, and Robert G Josse. The glycemic index: methodology and clinical implications. *The American journal of clinical nutrition*, Vol. 54, No. 5, pp. 846–854, 1991.
- [10] Search for the Glycemic Index. <https://www.glycemicindex.com/>.