

修士学位論文要約（令和4年3月）

回帰型ニューラルネットワークを用いた血糖値予測に関する研究

伊藤 雅基

指導教員：青木 孝文

Blood Glucose Prediction Using Recurrent Neural Networks

Masaki ITO

Supervisor: Takafumi AOKI

Diabetes is a disease that the blood glucose level is much higher than normal and can lead to severe complications. The most common treatment for diabetes is to inject insulin. The insulin dosage needs to be appropriately adjusted according to blood glucose since an overdose of insulin may cause dizziness and other symptoms. In this paper, we propose a method of predicting blood glucose levels using Long Short Term Memory (LSTM) to support insulin administration. A future blood glucose level is predicted based on past blood glucose levels, insulin dosage, and time information. Through experiments using our diabetes dataset, we demonstrate that the proposed method exhibits the efficient performance on blood glucose prediction.

1. はじめに

全世界の糖尿病患者数は、20年前と比較して3倍以上に増加しており¹⁾、その急激な増加が世界的な問題となっている。糖尿病は、血液中のブドウ糖の濃度（血糖値）が慢性的に高い状態（高血糖）となる病気である。血液中のブドウ糖は、すい臓から分泌されるインシュリンの働きによって細胞内に取り込まれる。すい臓のインシュリン分泌量低下や内臓脂肪によるインシュリン抵抗性の発現により、ブドウ糖が細胞内に取り込まれにくくなり、高血糖となる。糖尿病の治療法の一つにインシュリン注射がある。インシュリンを皮下注射することで、患者の血糖値を一時的に低下させる。ただし、インシュリンの過剰投与は、血糖値を急激に低下させ、意識障害等の副作用を引き起こす恐れがある。そのため、患者の症状や体質、生活習慣等を考慮して、インシュリンの投与量を調節することが重要である。インシュリンの投与量の調整方法として、責任インシュリン法とスライディングスケール法が主に用いられている²⁾。どちらの調整方法も医師が決めた量のインシュリンを任意のタイミングで投与する必要がある。血糖値の変動を予測することができれば、インシュリンの投与量や投与タイミングを自動的に調整することが可能となり、医師や患者の負担軽減につながる。現在までに、機械学習を用いて血糖値の変動を予測する手法が提案されている^{3) 4)}。いずれの手法も、血糖値の測定値に含まれるノイズや血糖値の急峻な変化により予測精度

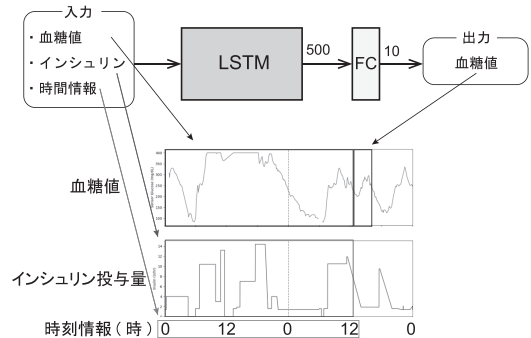


図1 提案手法の概要

が低下する。本論文では、Long Short Term Memory (LSTM)⁵⁾を用いた高精度な血糖値予測手法を提案する。過去の血糖値に加えて、インシュリン投与量や時刻情報を用いて LSTM を学習することで、未来の血糖値の予測精度を向上させる。また、学習に用いる血糖値データについて、データに含まれるノイズの低減のための平滑化を検討する。糖尿病患者に関するデータセットを用いた性能評価実験を通して、血糖値予測における提案手法の有効性を実証する。

2. 回帰型ニューラルネットワークを用いた血糖値予測手法

提案手法の概要を図1に示す。提案手法では、血糖値、インシュリンの投与量、時刻情報を入力とし、LSTMを用いて将来の血糖値を出力する。LSTMは過去のデータを線形和で保持し、勾配消失・発散問題

を回避するように設計されたネットワークのことである⁵⁾。4000点(約2週間)もしくは6000点(約3週間)の血糖値をLSTMの入力とし、LSTMの出力(500次元)を全結合層に入力することで、10点(50分)先までの血糖値の予測を行う。血糖値の予測期間は、予測精度や学習時間を考慮して10点とした。

(i) 血糖値データの平滑化

測定された血糖値データにはノイズや急峻な変化が含まれる。これらの影響を低減するため、血糖値データに対してSavitzky-Golay法を用いて平滑化を行う。平滑化によりLSTMが血糖値の変動を学習しやすくなると考えられるため、長期間の血糖値データに対する予測精度を向上させる。

(ii) インシュリン投与量の前処理

インシュリン製剤には、即効型インシュリン製剤や持効型溶解インシュリン製剤など複数の種類がある。投与から効果発現までに要する時間や効果の持続時間がそれぞれ異なるため、症状や治療方法に応じて使い分けられている。本論文では、投与されたインシュリンの種類に応じて、瞬間的な投与量を時間ごとの実効投与量に変換し、血糖値予測のために用いる。

(iii) 血糖値と時刻の関係性

血糖値は食後や就寝時に上昇する。そのため、生活リズムが一定の場合は時刻情報と血糖値の間に一定の相関があると考えられる。時刻情報を補助情報として用いることで、血糖値予測の精度を向上させる。

3. 糖尿病患者に関するデータセットを用いた精度評価実験

本論文では、東北大学大学院医学系研究科糖尿病代謝内科分野で取得・作成された糖尿病患者に関するデータセットを用いて提案手法の有効性を検証する。LSTMの入力は血糖値、インシュリン投与量、時刻情報の3つであり、損失関数は二乗平均誤差(Mean Squared Error: MSE)である。評価指標には、平均絶対誤差(Mean Absolute Error: MAE)と二乗平均平方根誤差(Root Mean Squared Error: RMSE)を用いる。血糖値データに対する平滑化の有無、およびLSTMの入力点数(4,000点、6,000点)の影響を評価する。血糖値は5分おきに測定されており、入力点数が多くなると、入力血糖値データの期間が長くなる。実験結果を表1に示す。平滑化を用いず、6,000点を入力した場合に最も予測精度が高い。この場合の血糖値のグラフを図2に示す。実測値と予測値の差が小さく、グラフの形も近い。平滑化の処理を加えると、学習時に微細な変化を学習できなくなり、入力点数が6,000点の場合の予測精度が低下したと




図2 予測結果のグラフ

表1 予測精度の比較

平滑化	入力点数	MAE (mg/dL)	RMSE (mg/dL)
なし	4,000	35.68	41.98
	6,000	23.13	30.13
あり	4,000	30.43	37.52
	6,000	27.79	35.68

考えられる。

4. まとめ

本論文では、回帰型ニューラルネットワークを用いた高精度な血糖値予測手法を提案した。糖尿病患者に関するデータセットを用いた性能評価実験を通して、血糖値予測における提案手法の有効性を実証した。今後の展望として、血糖値の予測結果に基づいて、一定の血糖値を維持するようにインスリンの投与量と投与タイミングを自動的に決定するシステムへの応用が考えられる。

文献

- 1) International Diabetes Federation, IDF Diabetes Atlas 9th edition, Int'l Diabetes Federation, 2019.
- 2) J.L. Schnipper, E.E. Barsky, S. Shaykevich, G. Fitzmaurice, and M.L. Pendergrass, "Inpatient management of diabetes and hyperglycemia among general medicine patients at a large teaching hospital," J. Hosp. Med., vol.1, no.3, pp.145–150, May 2006.
- 3) K. Li, J. Daniels, C. Liu, P. Herrero, and P. Georgiou, "Convolutional recurrent neural networks for glucose prediction," IEEE J. Biomedical and Health Informatics, vol.24, no.2, pp.603–613, Feb. 2020.
- 4) J. Chen, K. Li, P. Herrero, T. Zhu, and P. Georgiou, "Dilated recurrent neural network for short-time prediction of glucose," J. Healthcare Informatics Research, vol.4, pp.308–324, 2020.
- 5) S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural Computation, vol.9, no.8, pp.1735–1780, 1997.