

딥러닝 기반 노이즈 제거를 통한 장기 혈당 예측 안정성 향상

김수진, 김성호, 정성윤*

영남대학교

sujin38@yu.ac.kr, sunghokim@ynu.ac.kr, *syjung@ynu.ac.kr

Deep Learning-enhanced Noise Reduction for Robust Long-term Blood Glucose Prediction

Kim Su Jin, Kim Sung Ho, Jung Sung Yoon*

Yeungnam Univ.

요약

당뇨병 환자의 장기 혈당 예측은 인공췌장 시스템(Artificial Pancreas System, APS)의 안정적인 인슐린 조절을 위해 필수적이다. 그러나 연속 혈당측정(Continuous Glucose Monitoring, CGM) 데이터는 센서 노이즈를 포함하고 있어 예측 성능 저하를 야기한다. 본 연구에서는 딥러닝 기반 CNN-Autoencoder를 활용하여 CGM 데이터의 노이즈를 효과적으로 제거하고, 이를 바탕으로 장기 혈당을 예측하는 기법을 제안한다. 실험 결과, 제안한 기법은 기존의 전통적인 필터링 방법보다 우수한 노이즈 제거 성능을 보였으며, 24시간 혈당 패턴을 안정적으로 추정하였다. 특히 무작위 시나리오에서도 실제 혈당 추세를 잘 추종하는 결과를 보이며, 제안 기법이 장기 혈당 예측의 안정성과 신뢰성을 향상시킬 수 있음을 확인하였다. 본 논문은 선행 연구 [1]을 기반으로 주요 내용을 요약·정리하였다.

I. 서론

전 세계 당뇨병 환자 수가 증가함에 따라 효과적인 혈당 관리의 중요성이 점점 커지고 있으며, 이에 따라 정확한 혈당 예측 모델 개발이 활발히 진행되고 있다[2]. 특히 인공췌장 시스템(Artificial Pancreas System, APS)은 연속혈당측정(Continuous Glucose Monitoring, CGM) 센서, 인슐린 펌프, 그리고 제어 알고리즘으로 구성되어 환자의 혈당을 자동으로 조절하는 장치로 연구되고 있다. 효과적인 혈당 관리를 위해서는 CGM 센서를 활용한 연속 모니터링과 더불어 예측 기반 기술이 필수적이다. 그러나 CGM 데이터는 센서의 한계로 인해 노이즈가 포함되는 경우가 많아 혈당 예측의 정확도를 저하시킨다[3]. 따라서 이러한 노이즈를 효과적으로 완화하여 예측 정확성을 높이는 것은 중요한 연구 과제 중 하나이다.

이러한 문제를 해결하기 위해 본 연구에서는 CNN-Autoencoder를 활용하여 CGM 데이터의 노이즈를 제거하고, 이를 바탕으로 장기 혈당 패턴을 안정적으로 예측하는 기법을 제안한다[1].




그림 1. 노이즈 제거 결과 비교

II. 제안 기법 및 성능 비교

2.1 CNN-Autoencoder 기반 노이즈 제거

CGM 데이터는 센서 특성상 노이즈가 포함되어 있어, 혈당 예측 정확도 저하의 주요 원인이 된다. 본 논문에서는 CNN-Autoencoder 구조를 적용하여 노이즈를 효과적으로 제거하였다. CNN-Autoencoder는 인코더와 디코더로 구성된 신경망으로, 인코더는 입력 데이터를 저차원 잠재 공간으로 압축하면서 핵심 특징을 추출하고, 디코더는 이를 다시 복원하는 과정에서 불필요한 노이즈를 제거한다[4]. 본 연구에서는 CGM 데이터를 2차원 구조로 변환함으로써 공간적·시간적 패턴을 동시에 학습할 수 있도록 하였다. 그림 1은 기존의 Median filter와 제안한 CNN-Autoencoder의 노이즈 제거 결과를 비교한 것으로, 딥러닝 기반 접근법이 기존 선형 필터링 방식보다 우수한 성능을 보임을 확인할 수 있다. 또한, 표 1은 본 연구에서 사용된 주요 실험 파라미터를 정리한 것이다.

Parameter	Value
Total data	50,000
Epoch	30
Batch size	128
Optimizer	Adam
Loss	mse

표 1. Experimental parameters

2.2 Blood Glucose Pattern Estimator

딥러닝 기반 혈당 예측 모델들은 장기 예측 구간에서 오차가 누적되면서 성능이 점차 저하된다. 이를 보완하기 위해 본 연구에서는 혈당 변화를 선형 시스템 응답 함수로 모델링한 Blood Glucose Pattern Estimator (BGPE)를 제안하였다[1]. BGPE는 CHO 섭취와 인슐린 투여를 입력으로 받아 혈당 상승과 감소 효과를 동시에 반영하며, 이를 통해 24시간 혈당 패턴을 안정적으로 추정할 수 있다. 또한, 단순한 구조를 바탕으로 해석 가능성이 높고, 오차 전파를 최소화하여 장기 예측에서 기존 딥러닝 기반

모델보다 안정적인 성능을 기대할 수 있다.

BGPE는 입력 신호 $\mathbf{C}$ 를 섭취한 탄수화물(CHO), 시스템 모델 $\mathbf{h}$ 를 인체의 혈당 반응 (식사로 인한 상승과 인슐린 작용에 의한 감소)으로 모델링한다. 이때 혈당 변화 $\mathbf{G}$ 와의 관계는 다음과 같다.

$$\mathbf{G} = \mathbf{D}(\mathbf{C})\mathbf{F}_L\mathbf{h} + \mathbf{N} \quad (1)$$

여기서 $\mathbf{N}$ 은 측정 및 모델링 노이즈를 의미한다. $\mathbf{F}_L$ 은 Discrete Furier Transform 행렬이다.

이러한 정의를 바탕으로 주파수 영역에서 결합된 확률 변수 $\mathbf{Z}$ 를 구성하고, 추정된 $\hat{\mathbf{h}}$ 는 최대우도추정(MLE)을 통해 다음과 같이 계산된다[1].

$$\hat{\mathbf{h}} = ((\mathbf{D}(\mathbf{C}^H\mathbf{C})\mathbf{F}_L)^H\mathbf{D}(\mathbf{C}^H\mathbf{C})\mathbf{F}_L)^{-1}(\mathbf{D}(\mathbf{C}^H\mathbf{C})\mathbf{F}_L)^H\mathbf{Z} \quad (2)$$

최종적으로 추정된 $\hat{\mathbf{h}}$ 를 통해 장기 혈당을 추정할 수 있다.

2.3 모의 실험

본 연구에서는 FDA에서 승인한 UVA/Padova 시뮬레이터 기반의 simglucose[5]를 이용하여, 10명의 가상 T1DM 환자 데이터를 대상으로 Custom 시나리오(규칙적인 CHO 섭취)와 Random 시나리오(불규칙적 CHO 섭취)를 설정하고 모델의 예측 성능을 평가하였다.




그림 2. Custom 시나리오에서의 혈당 예측 결과

Method	Custom scenario	Random scenario
Raw data	2.495	4.536
Median Filter	0.953	1.833
DL Filter	0.495	1.209

표 2. RMSE 비교 결과

그림 2는 Custom 시나리오에서의 예측 결과를 나타내며, 딥러닝 기반 노이즈 제거가 Median filter보다 원 신호에 더 가깝게 혈당 곡선을 복원함을 보여주며 24시간 장기 혈당 예측을 잘 수행하는 것을 알 수 있다. 표 2는 RMSE 비교 결과이며 딥러닝 필터가 Median filter 대비 크게 RMSE를 감소하는 것을 볼 수 있다.

그림 3은 Random 시나리오에서 기존 딥러닝 모델(LSTM[6], Nonstationary Traformer[7])과의 비교 결과이다. BGPE는 불규칙한 환경에서도 오차 누적을 최소화하여 실제 혈당 변동을 안정적으로 반영하며, 장기 예측에서 기존 모델 대비 우수한 성능 보인다.




그림 3. Random 시나리오에서 BGPE와 딥러닝 기반 모델의 장기 예측 비교

III. 결론

본 연구에서는 CGM 데이터의 노이즈를 제거하기 위해 CNN-Autoencoder를 적용하고, 장기 혈당 예측을 위해 BGPE를 제안하였다. 실험 결과, 제안 기법은 기존 Median filter 대비 RMSE가 크게 감소하였으며, Custom 및 Random 시나리오 모두에서 기존 딥러닝 기반 모델보다 안정적인 성능을 보였다. 향후 연구에서는 실제 환자의 CGM 데이터를 적용하여 알고리즘의 임상적 타당성을 입증하고, 다양한 환자군 및 상황에 대한 확장 연구를 진행할 예정이다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. RS-2023-00219725).

참 고 문 헌

- [1] Kim, Su-Jin, Jun Sung Moon, and Sung-Yoon Jung. "Long-term blood glucose prediction using deep learning-based noise reduction." ICT Express (2025).
- [2] Zimmet, Paul Z., et al. "Diabetes: a 21st century challenge." The lancet Diabetes & endocrinology 2.1 (2014): 56-64.
- [3] G. Sparacino, A. Facchinetti, C. Cobelli, 'Smart' continuous glucose monitoring sensors: online signal processing issues, Sensors 10 (7) (2010) 6751 - 6772.
- [4] S.S. Roy, et al., A robust system for noisy image classification combining denoising autoencoder and convolutional neural network, Int. J. Adv. Comput.Sci. Appl. 9 (1) (2018) 224 - 235.
- [5] J. Xie, Simglucose v0.2.1, 2018, [Online]. Available: <https://github.com/jxx123/simglucose>.
- [6] Md. Fazle Rabby, et al., Stacked LSTM based deep recurrent neural network with kalman smoothing for blood glucose prediction, BMC Med. Inform. Decis. Mak. 21 (1) (2021) 1 - 15.
- [7] Yong Liu, et al., Non-stationary transformers: Exploring the stationarity in time series forecasting, Adv. Neural Inf. Process. Syst. 35 (2022) 9881 - 9893.