

PPG와 기계학습을 활용한 혈당수치 예측 연구

박철구¹, 최상기^{2*}

¹소프트웨어융합연구소 대표, ²소프트웨어융합연구소 연구소장

The study of blood glucose level prediction using photoplethysmography and machine learning

Cheol-Gu Park¹, Sang-Ki Choi^{2*}

¹CEO, Software Convergence Institute Co., Ltd.

²Director of R&D Center, Software Convergence Institute Co., Ltd.

요약 논문은 광용적맥파(photoplethysmography, PPG) 센서에서 획득한 생체 신호, ICT 기술 및 데이터 기반의 혈당수치 예측 모델을 개발하고 검증하는 연구이다. 혈당 예측은 기계학습의 MLP 아키텍처를 이용하였다. 기계학습 모델의 입력층은 심박수, 심박변이도, 나이, 성별, VLF, LF, HF, SDNN, RMSSD, PNN50의 10개의 입력노드와 은닉층은 5개로 구성된다. 예측모델의 결과는 MSE=0.0724, MAE=1.1022 및 RMSE=1.0285이며, 결정계수(R^2)는 0.9985이다. 비채혈방식으로 디지털기기에서 수집한 생체신호 데이터와 기계학습을 활용한 혈당 예측 모델을 수립하고 검증하였다. 일상에 적용하기 위해 다양한 디지털 기기의 기계학습 데이터셋 표준화와 정확성을 높이는 연구가 이어진다면 개인의 혈당 관리에 대안적 방법이 될 수 있을 것이다.

주제어 : 혈당관리, 인공지능, 광센서, 디지털기기, 정보통신기술

Abstract The paper is a study to develop and verify a blood glucose level prediction model based on biosignals obtained from photoplethysmography (PPG) sensors, ICT technology and data. Blood glucose prediction used the MLP architecture of machine learning. The input layer of the machine learning model consists of 10 input nodes and 5 hidden layers: heart rate, heart rate variability, age, gender, VLF, LF, HF, SDNN, RMSSD, and PNN50. The results of the predictive model are MSE=0.0724, MAE=1.1022 and RMSE=1.0285, and the coefficient of determination (R^2) is 0.9985. A blood glucose prediction model using bio-signal data collected from digital devices and machine learning was established and verified. If research to standardize and increase accuracy of machine learning datasets for various digital devices continues, it could be an alternative method for individual blood glucose management.

Key Words : Blood glucose level management, Artificial intelligence, Optical sensor, Digital device, Information and Communication Technology

*Corresponding Author : Sang-Ki Choi(dumoak@naver.com)

Received November 17, 2022

Accepted December 20, 2022

Revised December 3, 2022

Published December 28, 2022

1. 서론

1.1 연구필요성

당뇨병은 혈당 관리가 필요하며, 장기적으로 심각한 합병증을 수반하는 세계적인 공중보건 문제이다[1]. 전 세계적으로 성인의 당뇨병 유병률은 2010년 약 6.4%였으며 2030년에는 7.7%까지 증가할 것으로 예측된다[2]. 당뇨병은 β 세포 기능 장애, 인슐린 저항성 및 고혈당증을 특징으로 하는 만성 대사 질환이다[1]. 제2형 당뇨병은 신체의 비효율적인 인슐린 사용으로 발생하며, 당뇨병증의 95% 이상이 제2형 당뇨병이다[3].

당뇨병은 신경병증, 망막병증, 콩팥병증, 허혈성 심장 질환, 말초혈관질환, 뇌혈관 질환 등 미세혈관 및 대혈관 합병증과 밀접하게 연관되는 질환이며, 당뇨병증 환자의 약 33 - 50%에서 장기 및 조직 손상을 초래한다[4]. 당뇨병 관리에서 혈당을 낮추면 미세혈관 합병증의 발생률이 감소하며, 혈압을 낮추면 심혈관 합병증의 발생률이 감소하고 미세혈관 합병증의 중증도도 감소한다[5]. 당뇨병은 인체의 고혈당 수준을 말하는 만성질환이다.

만 30세 이상의 성인의 당뇨병 유병률은 2011년에서 2019년사이 년 평균 11.7%이며, 남자는 년평균 13.6% 여자는 년 평균 9.7%로 남자가 더 높으며, 30세 이상 성인 10명 중 1명은 당뇨병 유병자이다[6]. 효과적인 당뇨병 관리에 대한 수요가 증가되고 있으며, 당뇨병으로 인한 말기 합병증을 피하기 위해 수시로 혈당을 모니터링하는 것이 중요하다.

혈당 모니터링은 기본은 채혈 방식이다. 채혈 방식은 lancet의 찌름 고통과 함께 잦은 측정은 외상을 유발할 수 있으며, 결국에는 혈당 모니터링을 포기하는 요인이 된다. 이 문제를 해결하기 위해 비침습적인 혈당모니터링 방법이 연구되고 있다. 효과적인 혈당관리를 위한 연구가 필요하며, 비채혈 방식은 새로운 연구분야로 대두되고 있다. 혁신적으로 발전하고 있는 디지털센서 기술, 기계학습 심층학습 예측모델 및 정보통신기술의 융합으로 혈당 수치를 비채혈적으로 관리하는 방법을 연구하여 일상에서 혈당 수치 관리에 도움이 되고자 한다.

1.2 연구목적

광용적맥파 (photoplethysmograph, PPG)를 이용하여 생체신호 데이터 획득, 정보통신기술과 및 컴퓨팅 환경에서 기계학습을 응용하여 비채혈적으로 혈당 예측

기계학습 모델 개발 및 검증 하는 방법을 연구하는 것이다.

논문에서는 비채혈 방식으로 디지털기기를 통해 수집되는 아날로그 생체신호 데이터를 PPG 디지털기기를 이용하여 획득된 디지털 수치 정보와 대사성 만성질환으로 알려진 일상의 혈당관리를 위한 혈당 예측 모델을 설계하고 검증하는 방법을 연구하고자 한다.

2. 이론

2.1 혈당 모니터링 기술

혈당 모니터링은 실험실 기반기술 또는 개인용혈당기를 이용하는 개인기반 모니터링으로 수행된다. 이 방식은 기본적으로 침습적 방식으로 점혈 또는 채혈을 위해 피부를 찌르는 불편함과 고통을 수반하며, 측정 시점의 혈당 수치만 파악한다. 고혈당증(Hyperglycemia)의 경우 혈당 관리를 위해 하루에 3-4 회이상 여러번 혈액 샘플을 채취하는 사용자에게 불편하며, 이런 방식을 꺼리게 된다. 따라서, 혈당 프로파일의 중요한 변화는 예상치 못한 부작용과 환자의 낮은 순응도로 인해 파악하지 못할 수 있다. 일반적으로 혈당은 70-140 mg/dL 범위에서 관리되어야 한다[7].

2.1.1 침습적 방법

침습적 방법은 혈당수치 측정을 위한 가장 보편화된 방법으로 소량의 혈액을 채취하기 위해 lancet 장치로 손가락 부위를 찌러 점혈하고, 측정기의 검사스트립에 혈액을 침적시켜 혈당 수치를 확인하는 것이다. 일반 약국에서 손쉽게 보급되고 있는 개인용혈당기를 사용하여 개인이 혈당 수치를 확인하고 관리할 수 있다.

2.1.2 비침습적 방법

최근 20 여년 전에 개발되고 지속적인 연구분야인 비침습적 방법은 분광법(임피던스, 라만, 편광, 생체 정전용량), 전기, 및 근적외선 등을 이용하여 혈당에 의한 신체에 지저 조직의 물리적 특성 변화를 측정한다.

PPG를 사용하여 비침습적 혈당을 추정하는 시스템이 제시되었다[8]. 근적외선은 750-2500nm의 파장 범위의 광선을 의미한다. 광 송신기와 수신기는 근적외선 영역에서 작동하는 센서가 사용된다. 근적외선 파장의 빛의 흡수 변화를 측정하여 PPG신호를 얻을 수 있다. 손가락의 정맥은 모든 심장 박동에 따라 확장하고 수축한다. PPG 신호 분석은 포도당 분자 검출 원리 기반이 아니

며, 심박동의 변화에 의한 혈류량 변화를 기반으로 한다.

3. 연구방법

3.1 연구대상자

연구대상자는 개인용 혈당기를 이용한 채혈방식의 혈당수치가 125mg/dl 이하인 정상인과 병원에서 당뇨병 증으로 진단을 받고 약을 복용하고 있는 18세에서 70세의 자발적인 참여자 70명을 대상으로 하였다.

3.2 연구기간

연구에 필요한 데이터 수집은 2022년 10월 기간에 수행하였다.

3.3 연구도구

연구 도구는 PPG 디지털기기, 개인용혈당기, WiFi통신장비, 컴퓨팅 시스템을 이용하였다.

3.3.1 PPG 디지털기기

생체 정보를 수집하기 위해 PPG 센서를 이용하였다 (Table 1). PPG디지털기기는 광발광소자, 광센서, 마이크로 컨트롤러 및 통신용 송수신기로 구성되는 디지털 기기이다(Fig. 2).

Table 1. PPG Specifications

Attribute	Characteristics
IR LED (ILED = 20mA, TA = +25°C)	
LED Peak Wavelength	870 880 900nm
Full Width at Half Max	30nm
Foward Voltage	1.4V
Radiant Power	6.5mW
RED LED (ILED = 20mA, TA = +25°C)	
LED Peak Wavelength	650 660 670nm
Full Width at Half Max	20nm
Foward Voltage	2.1V
Radiant Power	9.8mW
Photodector	
Spectral Range of Sensitivity	600 900nm
Radiant Sensitive Area	1.36mm ²
Dimensions of Radiant Sensitive Area	1.38mm x 0.98mm
RF Interface Type	IEEE802.11 b/g/n/e/(Wi-Fi)
Operating Voltage	DC 3.7V
output rate	1 Hz

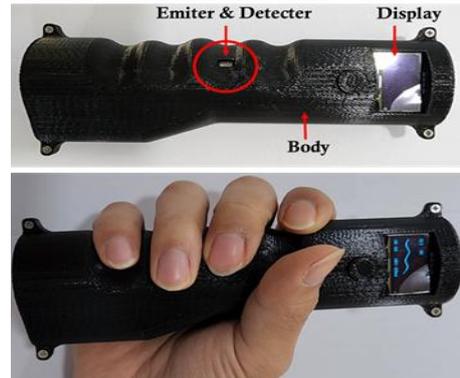


Fig. 2. photoplethysmography(PPG)

3.3.2 개인용혈당관리시스템

개인용혈당기는 자가혈을 채취하여 혈액내 포도당의 양을 측정하기 위한 진단기기를 이용하여 혈당 수치 정보를 수집한다[9]. 참조 혈당수치를 확인하기 위해 연구에 사용된 개인용혈당기의 사양은 Table 2와 같다.

Table 2. Blood glucose meter specifications[10]

Attribute	attribute value
ISO Compliance	EN ISO 15197:2015 & ISO 15197:2013
Method	electrochemical
Sample size	0.5μL
Blood Sample Types	Capillary, venous
Measurement range	20-600 mg/mL
Measurement time	5 Seconds
Memory capacity	Memory can store 1000 tests
Haematocrit range	15-65%
battery	3V lithium battery, 2pcs (Model: CR2032)
Display	LCD
size	93 x 47 x 15mm (length x width x height)
weight	Approximately 51.5 g (with batteries)

3.3.3 통신장비

WiFi 통신 환경은 ipTIME A3008-MU 모델을 사용하여 구성하였으며, 표준 TCP/IP 통신 프로토콜을 사용하였다.

3.3.4 컴퓨팅 환경

컴퓨팅 환경은 PPG 송신 데이터의 지속적인 수집, 저장 및 예측을 위한 기계학습을 수행할 수 있다. 데이터

관리는 데이터베이스 시스템을 사용하였다(Table 3).

Table 3. Computing system specifications

Type	Specifications
CPU	Intel(R) Core(TM) i9-9900K 3.60GHz
RAM	32GB
OS	Windows 10 Pro. 21H2. 64bit
RDBMS	MySQL 6.4

3.4 데이터수집

인체의 생체 신호는 PPG 디지털기기를 이용하여 2분 동안의 심박수의 데이터를 수집하였다. 센서를 이용한 데이터 획득 후 혈당 수치는 개인용혈당기를 이용하여 혈당 수치를 확인하였다. PPG 디지털기기를 통해 수집되는 정보는 심박수, 심박변이도, VLF, LF 및 HF이다.

PPG 디지털기기는 광센서와 임베디드 시스템의 검출 알고리즘을 통해 심박수(HR, Heart Rate), 심박변이도(HRV, Heart Rate Variability), 초저주파대(VLF, Very Low Frequency Band), 저주파대(LF, Low Frequency Band), 고주파대(HF, High Frequency Band) 데이터를 획득하여 정보통신 환경에서 근거리, 원거리 컴퓨팅 환경에 데이터를 전송할 수 있다.

3.4.1 수집 방법

생체신호 데이터를 수집을 위한 개념도이다[Fig.3]. 데이터 획득 영역은 디지털기기를 이용하여 사람의 생체 정보를 수집하는 영역이다. PPG 디지털기기에 수집되는 데이터는 정보통신 기술을 이용하여 컴퓨팅 환경으로 전송된다. 컴퓨팅 환경은 TCP/IP 프로토콜 기반의 통신환경에서 1초 단위로 전송되는 정보를 수신하여 데이터베이스시스템(RDBMS)에 저장한다. 그리고 데이터는 기계학습용 데이터셋으로 표준화하기 위해 전처리 과정을 수행한다.



Fig. 3. Data collection diagram

연구대상자는 의자에 착석하고, 안정된 상태에서 PPG기기를 3분 동안 움직임이 없이 오른손으로 가볍게 움켜잡고 있으면 PPG 디지털기기는 생체신호 데이터를 수집한다. 센서 데이터 수집이 완료된 이후, 연구대상자는 개인용혈당기를 이용하여 손끝을 연구대상자가 직접 점혈하여 혈당수치를 확인하고, 기록하였다.

3.4.2 HRV의 시간영역 값

혈당 예측모델 개발을 위해 PPG 디지털기기에 심박수(HR), 심박변이도(HRV), VLF, LF 및 HF 정보를 수집된다. 그리고 HRV 값에서 계산되는 시간영역 데이터인 SDNN, RMSSD, PNN50 값을 계산하여 기계학습의 입력 변수로 활용하였다.

3.5 분석방법

PPG 디지털 기기에서 수집된 정보는 SPSS(Ver. 23)을 사용하여 데이터 통계과 상관분석을 실시하였다. 기계학습 예측 알고리즘은 Python(Ver. 3.8)과 Tensorflow를 사용하여 ANN 알고리즘을 구현하였다. 사용한 라이브러리는 Keras, Pandas, Matplotlib 등이다. 예측한 혈당수치는 개인혈당기로 측정한 원시 데이터와 비교하였고 Clarke Error Grid Analysis를 사용하여 시각화하였다.

3.5.1 데이터 선별

표준 데이터셋에서 다음의 경우는 데이터를 제거하였다.

- 이상치 검출 : PPG 디지털기기의 이상치는 검출하고 제거하였다. 심박수 값이 0이면 제거하였다.
- 중복값 처리 : 연속된 생체신호의 수집은 데이터의 중복이 나타날 수 있다. 중복데이터는 1개의 데이터만 선별하였다.

3.5.2 예측 지표

회귀 예측의 지표는 실제 값과 회귀 예측값의 차이로 평가한다. 회귀 지표에 적용된 평균 절대 오차(MAE, Mean Absolute Error), 평균 제곱 오차(MSE, Mean Squared Error), 평균 제곱근 오차(RMSE, Root Mean Square Error)는 값이 작을수록 예측 값과 실제 값의 차이가 없고, 예측 성능이 우수하다고 해석할 수 있다 [11]. 반면 결정계수(R^2)는 1에 근접한 값이 성능이 우수하다. 예측 비용함수로 MSE를 사용하였다.

3.5.3 Clarke error grid

Clarke Error Grid는 임상정밀도를 검사하기 위한 벤치마크 도구이다. 1987년 Clarke가 제시한 “error grid”는 기기를 통해 측정된 값과 임상 표준기기의 혈당 수치와 맵핑하여 표시한 그래프이다(Fig.6)[12]. 그리드는 5개 오류 영역(zone A, B, C, D, E)으로 구분된다. 값이 영역 A 또는 영역 B에 있으면 Beckman 분석기에 따라 만족스럽거나 정확한 포도당 결과 예측을 의미한다.

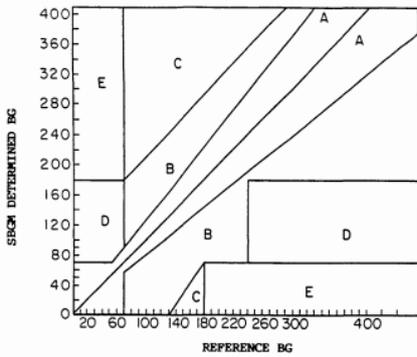


Fig. 6. Clarke error grid

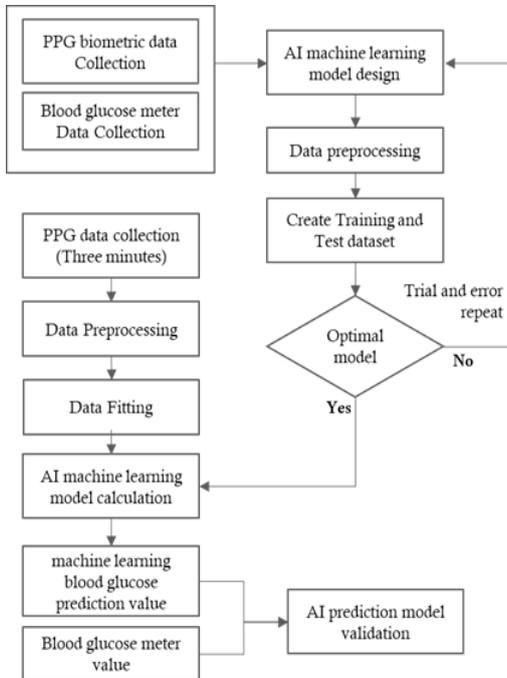


Fig. 7. Blood glucose prediction model

3.6 예측모델 개발

예측모델은 PPG 디지털기기의 획득 데이터와 기계 학습 딥러닝으로 혈당 수치를 예측하는 모델이다. 예측 모델 개발에 필요한 데이터는 지원자 70명에서 획득한 데이터와 선형 회귀로직을 이용하여 모델링하였다.

예측 알고리즘의 시작 과정은 참조 데이터셋을 수집하는 것이다. 예측 알고리즘에 활용된 데이터는 PPG 디지털기기를 이용하여 사람의 생체정보(심박수, 심박변이도, VLF, LF, HF)를 획득한다. 그리고 임상표준 개인용 혈당기를 사용하여 혈당 수치를 수집하였다. 계속적으로 혈당 수치 예측을 위해 참조 데이터 셋으로 기계학습 딥러닝 알고리즘을 모델링하였다. 딥러닝 예측 모델 및 결과의 정확도를 파악하기 위해 연구자의 샘플링 데이터로 혈당수치를 비교 검증하였다(Fig. 7).

4. 연구결과 및 고찰

4.1 데이터 분석

4.1.1 연구대상자 특성

혈당 예측 모델 개발을 위한 PPG 데이터 수집 대상자는 10대에서 70대의 70명이다. PPG 데이터 수집 대상자의 통계 정보는 <Table 5>이다.

Table 5. PPG data age distribution

Age Group	Male (n=46)	Female (n=24)	M	SD
10	3	0	32.58	11.22
20	26	14		
30	6	8		
40	3	0		
50	8	1		
70	0	1		

4.1.2 데이터 평가

PPG 수집 데이터의 유의성을 검증하였다. Wilconxon signed rank test 분석 결과는 Table 6과 같다. 당뇨병증(+T2DM) 기준은 혈당수치 > 126 mg/dL이다.

Table 6. Statistical analysis result

variable	-T2DM (M±SD) (n=3,498)	+T2DM (M±SD) (n=862)	p Value
HR	78.16 ± 10.64	76.71 ± 13.22	<.000
HRV	37.11 ± 94.17	7.68 ± 100.64	<.000
SDNN	52.83 ± 4.60	53.63 ± 5.17	<.000
RMSSD	72.91 ± 7.66	77.53 ± 10.22	<.000
PNN50	0.51 ± 0.71	0.53 ± 0.07	<.000
VLF	1393.45 ± 3615.79	1032.95 ± 1159.29	<.000
LF	5774.44 ± 11958.65	6709.36 ± 7915.36	<.000
HF	21358.86 ± 51834.46	28648.89 ± 47843.22	<.000
BG	106 ± 11	151 ± 39	<.000

디지털기에서 획득되는 데이터를 통계적으로 정상(-T2DM)과 당뇨병증(+T2DM) 두 그룹 간의 평균 차이의 분석한 결과는 정상과 당뇨병증 그룹 간의 HR, HRV, VLF, LF, HF, SDNN, RMSSD, PNN50 값은 유의한 차이($p < .000$)가 있었다.

4.1.3 변수별 상관관계 평가

PPG 디지털기기를 통해 수집된 데이터셋의 변수 간 피어슨 상관관계를 분석하였으며, 결과는 <Table 7>과 같다.

Table 7. Correlation matrix (n=4,360)

	HR	HRV	VLF	LF	HF	Gen.	Age	BG
HR	1							
HRV	.059**	1						
VLF	.062**	-.022	1					
LF	.130**	-.042**	.937**	1				
HF	.211**	-.043**	.596**	.786**	1			
Gen.	.002	-0.90**	-.123**	-.032**	.011	1		
Age	-.087**	.058**	-.129**	-.134**	-.162**	-.049**	1	
BG	.228**	-.134**	.019	.141**	.141**	.030*	.182**	1

*P <0.05 **P <0.01

- HR(Heart Rate)
- HRV(Heart Rate Variability)
- VLF(Very Low Frequency Band)
- LF(Low Frequency Band)
- HF(High Frequency Band)
- Gen.(Gender)
- BG(Blood Glucose)

Table 7은 PPG에서 수집되는 변수들에 대한 상관행

렬표이다. PPG 변인들 간의 상관계수는 전체적으로 0.937에서 -0.162이며, 유의수준은 $P < .01$ 또는 $P < .05$ 에서 통계적으로 검증된다.

4.2 혈당 예측모델 설계

혈당수치 예측모델은 다변량 선형 회귀 모델과 기계학습 딥러닝 신경망(ANN)을 이용하여 모델을 활용하였다.

데이터 셋은 PPG 디지털기에서 획득한 HR, HRV, VLF, LF, HF와 개인용혈당기에서 수집한 혈당 수치 및 나이와 성별을 라벨링하여, 입력층노드값으로 사용하였다. 또한, SDNN, RMSSD, PNN50 라벨링 값은 HRV에서 시간영역 값을 구하였다. 데이터는 HR > 0 이상인 경우만 채택하고, 나머지 경우는 제거하였다. 데이터 셋은 학습용과 검증용으로 분할되며, 학습용은 데이터셋의 75%로 설정하였다. 데이터는 scaling 방법을 적용하여 예측 정확도를 높이는 선행작업이 적용된다.

4.3 구현 및 결과

4.3.1 인공신경망

예측을 위한 기계학습은 지도학습에 대한 잘 알려진 딥러닝 인공신경망인 MLP를 활용하였다(Fig. 8).

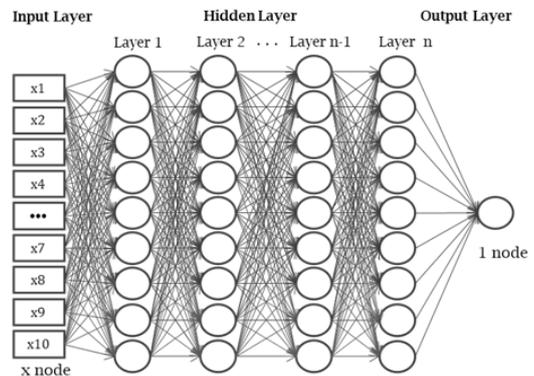


Fig. 8. MLP architecture

MLP 모델은 1개의 입력층, 5개의 은닉층 및 혈당 예측 수치를 표시하는 1개의 출력층으로 구성된다. 입력층에는 획득된 생체정보 및 계산된 변수로 10개의 라벨링된 변수를 사용하였다. 입력층은 각각 64, 128, 256, 512의 노드가 있는 은닉층으로 전달된다.

4.3.2 하이퍼파라미터 설정

기계학습 딥러닝 예측모델에서 하이퍼파라미터 설정 작업은 중요한 프로세스이며, 파라미터 정보는 TensorFlow의 keras 예측모델 라이브러리에 사용하였다. Table 8에는 기계학습 MLP 아키텍처 혈당 예측 모델에 적용된 하이퍼파라미터 값이다.

Table 8. Hyperparameters

Property	Method
Weight Initialization	normal
Activation Functions	relu, linear
Optimizaiton(updater)	adam
Backporpagation	True
Backporpagation Method	Mini-batch, gradient descent
Mini-batch	64
Loss Function	mse
Regularization	true
Number of epochs	60

4.3.3 은닉층 수에 의한 영향 분석

기계학습 모델의 하이퍼파라미터와 은닉층은 예측값에 영향을 미칠수 있다. 혈당 예측값과 참조값의 정확도를 평가하기 위해 MAE, MSE, RMSE, 결정계수(R^2) 값을 확인하였다. 예측 데이터를 평가하기 위해 Clarke 오류그리드 분석(Error Grid Analysis)를 이용하여 시각화하였다(Fig.9)[13].

Table 9. Performance evaluation result in Machine Learning

number of hidden layers		5 times Average			
		MAE	MSE	RMSE	R^2
HL4	Training	0.8011	1.2567	1.9982	
	Valid	0.8171	1.3390	1.1329	0.9981
HL5	Training	0.7073	1.0218	0.9874	
	Valid	0.0724	1.1022	1.0285	0.9985
HL6	Training	0.7073	1.0100	0.9986	
	Valid	0.7240	1.1022	1.0285	0.9985
HL7	Training	0.8262	1.3591	1.1117	
	Valid	0.8398	1.4196	1.1385	0.9980

Table 9는 기계학습 MLP 예측모델에서 은닉층의 영향을 확인하기 위해 은닉층을 변경하면서 결정계수(R^2)를 확인하였다. 기계학습 모델의 예측 성능은 은닉층 변경 모델별 각 5회의 예측 평가지표에 대한 평균 값이다. 은닉층이 5개 또는 6개 층인 경우, 기계학습 예측 모델에서 최적의 성능을 보였다. 더 적은 은닉층이 컴퓨팅 성능면에서 유리할 수 있으므로 5개 은닉층 모델을 적용한다. 5개 은닉층을 사용한 경우, 학습에서 평균 MSE, MAE 및 RMSE 값의 각각 0.7073, 1.0218 및 0.9874이며 검증에서는 각각 0.0724, 1.1022, 1.0285이며, 결정계수(R^2) 수치는 0.9985이다.

[Fig.9]은 MLP 아키텍처를 이용한 기계학습 혈당수치 예측값과 개인용혈당기의 실측값 간의 값의 비교를 시각화한 그래프이다. Clarke Error Grid Analysis를 이용하여 실측값과 예측값의 쌍을 그래프로 시각화한 결과이며 영역 "A"에 분포한 확률은 100%이다. x축은 개인용혈당기의 실측값이며 y축은 기계학습 예측모델의 혈당 수치 예측값이다.

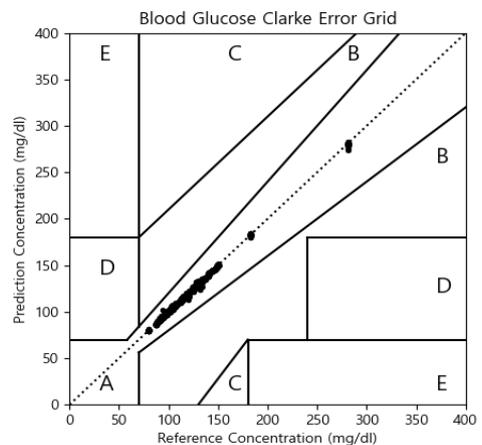


Fig. 9. Clarke EGA Result(at HL5)

Clarke Error Grid Analysis에서 그래프로 시각화하여 표시된 값은 정확도 있는 것으로 간주된다. 오류 그리드에서 차이가 20% 이하인 경우 영역 A에 배치된다(혈당 수치 > 70 mg/mL 이상인 경우).

4.3.4 연구결과 고찰

4.3.4.1 혈당수치예측

기계학습 모델을 이용한 혈당수치 예측 결과는 딥러

닝 MLP 아키텍처에서 은닉층 5개를 적용할 때 우수한 결과를 보였다. 입력층 변수는 HR, HRV, 주파수영역 측정값은 VLF, LF, HF와 시간영역 계산값인 SDNN, RMSSD, PNN50 및 나이와 성별이다,

예측 모델 연구에서 생체정보 수집은 비침습적이고 광기술이 적용된 PPG 디지털기기를 이용하였으며, 비채혈적으로 생체신호인 심박수와 심박변이도의 데이터 기반으로 혈당수치 예측모델 수립과 예측 값의 정확도를 검증할 수 있었다,

연구 결과는 심장 박동으로 나타나는 생체 신호가 비채혈 방식의 혈당 수치 예측의 진단변수로 활용 될 수 있을 것으로 사료된다.

4.3.3.2 한계점

연구는 개인용혈당기에서 측정한 혈당 수치를 기준으로 이용하였다. 기준값의 혈당 수치 범위는 80 - 300 mg/dL의 범위이며, 공복혈당 수치 기준이다.

5. 결론

인체의 심박수 변화를 측정할 수 있는 PPG 디지털기기를 이용하여 생체신호 획득, 정보통신기술과 컴퓨팅 환경에서 기계학습을 응용하여 비채혈적으로 딥러닝 혈당예측 모델 설계 및 그 모델을 검증하는 방법을 연구하는 것이다.

기계학습 모델을 개발하기 위해 표준 데이터셋을 생성하였다. 인체의 생체신호는 PPG 디지털기기를 이용하여 2분 동안의 심박수의 데이터를 수집하였다. 혈당예측 모델은 기계학습을 이용하였고, 은닉층 5개의 MLP 모델에서 성능지표가 최적이었다. 입력층 변수는 HR, HRV와 주파수영역 측정값인 VLF, LF, HF 및 시간영역 계산 값인 SDNN, RMSSD, PNN50, 그리고, 나이와 성별이다. 예측 값의 성능은 평균 MSE, MAE 및 RMSE으로 평가하며, 학습에서 각각 0.7073, 1.0218, 0.9874이며 검증에서는 각각 0.0724, 1.1022, 1.0285이다. 결정 계수(R^2) 값은 0.9985이다.

만성 질환인 당뇨병의 혈당관리는 합병증을 예방하는데 필수적이며, 삶의 질을 유지하는데 필요하다. 디지털 기기와 정보통신기술 및 기계학습이 융합한 혈당 예측은 단편화된 생체신호의 무의미한 정보를 신개념의 데이터 해석으로 의학적으로 유의미하게 해석이 가능하였

으며, 실생활에서 활용될 수 있는 가능성을 파악할 수 있었으며, 편리한 혈당수치 모니터링은 자기주도적으로 건강관리를 실행할 수 있을 것이다.

PPG 디지털기기의 생체신호의 활용은 컴퓨팅 환경의 기술 발전으로 지속적으로 연구로 계속 발전되고 있다. 비채혈적으로 획득할 수 있는 생체정보를 이용하여 당뇨병의 혈당 수준 관리를 위한 혈당 수치 관리에 응용할 수 있는 정확도를 가질 수 있음을 검증할 수 있었으며, 생체신호를 획득할 수 있는 다양한 디지털기기를 활용하기 위한 기계학습 데이터셋의 표준화 작업을 위한 연구가 이어진다면 일상에서 채혈방식의 혈당수준 관리의 대안적 방법으로 자리매김 할 수 있을 것으로 사료된다.

REFERENCES

- [1] H. Wu et al. (2022) Diabetes and Its Cardiovascular Complications: Comprehensive Network and Systematic Analyses. *Front. Cardiovasc. Med.* 9:841928. DOI: 10.3389/fcvm.2022.841928
- [2] J. E. Shaw, R. A. Sicree & P. Z. Zimmet. (2010). Global estimates of the prevalence of diabetes for 2010 and 2030. *Diabetes research and clinical practice*, 87(1), 4-14. DOI : 10.1016/j.diabres.2009.10.007
- [3] WHO. (2022.9.16.). *Diabetes*(Online). <https://www.who.int/news-room/fact-sheets/detail/diabetes>
- [4] UK Prospective Diabetes Study (UKPDS). (1991). VIII. Study design, progress and performance. *Diabetologia*, 34(12), 877-890.
- [5] S. Genuth et al. (2003). Implications of the United kingdom prospective diabetes study. *Diabetes care*, 26, S28-S32. DOI : 10.2337/diacare.26.2007.s28
- [6] Korea Disease Control and Prevention Agency. (2021). Trends in prevalence of diabetes among Korean adults aged 30 years and over, 2011-2019. Division of Chronic Disease Control, Korea Disease Control and Prevention Agency. *Weekly Health and Disease*, 14(46).
- [7] J. S. Kinsley & J. C. Preiser. (2015). Time in blood glucose range 70 to 140 mg/dl >80% is strongly associated with increased survival in non-diabetic critically ill adults. *Critical care (London, England)*, 19(1), 179. DOI : 10.1186/s13054-015-0908-7

- [8] S. Habbu, M. Dale & R. Ghongade. (2019). Estimation of blood glucose by non-invasive method using photoplethysmography. *Sādhanā*, 44(6), 1-14.
DOI : 10.1007/s12046-019-1118-9.
- [9] Ministry of Food and Drug Safety. (2019.09.23). *Blood glucose monitoring systems, self-testing (Online)*.
https://udiportal.mfds.go.kr/brd/view/P03_01?ntceSn=14
- [10] CareSensPRO. (2021. 11. 25). *User's Manual: Blood Glucose Monitoring System(Online)*.
https://i-sens.com/pdf/ko/2021/PGUAA-0000038-REV1-CS-PRO-M-Manual-KR_Positive-LCD.pdf
- [11] S. K. Choi & C. G. Park. (2021). The study of blood glucose level prediction model using ballistocardiogram and artificial intelligence. *Journal of Digital Convergence*, 19(9), 257-269.
DOI : 10.14400/JDC.2021.19.9.257
- [12] W. L. Clarke et al. (1987). Evaluating clinical accuracy of systems for self-monitoring of blood glucose. *Diabetes care*, 10(5), 622-628.
DOI : 10.2337/diacare.10.5.622
- [13] W. L. Clarke. (2005). The original Clarke Error Grid Analysis (EGA). *Diabetes technology & therapeutics*, 7(5), 776-779.
DOI : 10.1089/dia.2005.7.776

박철구(Cheol-Gu Park)

[정회원]



- 2016년 4월 ~ 현재 소프트웨어융합 연구소 대표
- 2014년 명지대학교 산업경영공학 박사
- 2010년 KTDS 품질생산성연구소 팀장
- 2005년 순천대학교 정보통신 공학 석사
- 관심분야 : 인공지능, 심탄도 응용, 만성질환 예측
- E-Mail : pck3867@naver.com

최상기(Sang-Ki Choi)

[정회원]



- 2022년 8월 : 선문대학교 통합의학과 의학박사
- 2016년 4월 ~ 현재 : 소프트웨어융합 연구소 연구소장
- 관심분야 : 웰니스, 융합 의과학, IT Convergence
- E-Mail : dumoak@naver.com