

# 심탄도와 인공지능을 이용한 혈당수치 예측모델 연구

최상기<sup>1</sup>, 박철구<sup>2\*</sup>

<sup>1</sup>소프트웨어융합연구소 연구소장, <sup>2</sup>소프트웨어융합연구소 대표

## The study of blood glucose level prediction model using ballistocardiogram and artificial intelligence

Sang-Ki Choi<sup>1</sup>, Cheol-Gu Park<sup>2\*</sup>

<sup>1</sup>Director of R&D Center, Software Convergence Institute Co., Ltd.

<sup>2</sup>CEO, Software Convergence Institute Co., Ltd.

요 약 논문은 심탄도(BCG, Ballistocardiogram) 센서를 이용하여 생체신호 데이터를 비침습, 무구속적인 방식으로 수집하고, ICT 기술과 고성능 컴퓨팅 환경에서 인공지능 기계학습 알고리즘을 활용하여 데이터 기반 혈당 예측 알고리즘 모델 개발 및 검증하는 방법을 제시하고 연구하는 것이다. 혈당수치 예측모델은 MLP 아키텍처에 입력노드는 심박수, 호흡수, 심박출량, 심박변이도, SDNN, RMSSD, PNN50, 나이, 성별이며, 은닉층 7개를 사용하였다. 실험 결과는 5회 실험한 학습데이터의 평균 MSE, MAE 및 RMSE 값은 각각 0.5226, 0.6328 및 0.7692이며 검증데이터 평균 값은 각각 0.5408, 0.6776, 0.7968이었으며, 결정계수(R<sup>2</sup>) 수치는 0.9997의 결과를 보였다. 데이터를 기반으로 한 혈당수치를 예측하는 모델을 표준화하고 데이터셋 수집과 예측 정확성을 검증하는 연구가 계속적으로 진행된다면 비침습 방식의 혈당 수준 관리에 활용될 수 있을 것으로 사료된다.

주제어 : 혈당수치 예측, MLP, 딥러닝, 심박변이도, IoT 디지털기기, ICT 융복합

Abstract The purpose of this study is to collect biosignal data in a non-invasive and non-restrictive manner using a BCG (Ballistocardiogram) sensor, and utilize artificial intelligence machine learning algorithms in ICT and high-performance computing environments. And it is to present and study a method for developing and validating a data-based blood glucose prediction model. In the blood glucose level prediction model, the input nodes in the MLP architecture are data of heart rate, respiration rate, stroke volume, heart rate variability, SDNN, RMSSD, PNN50, age, and gender, and the hidden layer 7 were used. As a result of the experiment, the average MSE, MAE, and RMSE values of the learning data tested 5 times were 0.5226, 0.6328, and 0.7692, respectively, and the average values of the validation data were 0.5408, 0.6776, and 0.7968, respectively, and the coefficient of determination (R<sup>2</sup>) was 0.9997. If research to standardize a model for predicting blood sugar levels based on data and to verify data set collection and prediction accuracy continues, it is expected that it can be used for non-invasive blood sugar level management.

Key Words : Blood glucose level prediction, MLP, Deep Learning, Heart Rate Variability, IoT Digital device, ICT Convergence

\*Corresponding Author : Cheol-Gu Park(pck3867@naver.com)

Received July 30, 2021

Accepted September 20, 2021

Revised August 22, 2021

Published September 28, 2021

## 1. 서론

### 1.1 연구필요성

#### 1.1.1 연구필요성

당뇨병 만으로는 건강에 영향을 미치지 않지만 그 합병증은 항상 사람들의 건강에 위협을 초래한다[1]. 당뇨병 발병을 예방하고 당뇨병을 발견하기 위해 혈당수치와 당화혈색소(A1C, glycated hemoglobin)를 확인하기 위해 정기적으로 혈액 검사로 확인하는 것이 필요하다[2].

당뇨병 관리 절차에서 혈당 수치 모니터링은 매우 큰 장점이 있다. 단기적 이점의 관점에서 혈당 모니터링은 혈당 변동을 관리하고, 약물 및 식단 일정을 조절하고, 고혈당 및 저혈당 이벤트를 모니터링하고 케톤산증을 예방할 수 있다[3, 4]. 장기적인 이점의 관점에서 혈당을 조절하면 당화 헤모글로빈 수치를 개선하고 미세 혈관 및 거대 혈관 질환의 발생률을 줄이고 사망률을 줄일 수 있다[5, 6].

혈당 조절 시스템이 실패하면 혈당(Blood Glucose) 수치가 정상 혈당 범위를 초과하게 된다. 당뇨병의 만성 고혈당증은 다양한 장기, 특히 눈, 신장, 신경, 심장 및 혈관의 장기적인 손상, 기능 장애 및 부전과 관련이 있다[7]. 저혈당증과 고혈당증은 각각 단기 및 장기 합병증을 유발할 수 있다. 혈당은 중요한 생리학적 매개 변수이며 지속적이거나 주기적으로 모니터링이 필요하며, 당뇨 관리의 시작은 혈당수치를 표준 범위 내에서 관리되도록 하는 것이다.

자가혈당관리시스템을 이용한 혈당 모니터링은 수행되는 순간에만 환자에게 혈당 농도를 알려주는 불연속적인 과정이며 혈액을 구하기 위해 반드시 채혈이 필요하며 채혈시마다 고통스럽고 불편하여 결국에는 혈당관리를 포기하게 된다. 이 문제를 해결하기 위해 비침습적인 혈당모니터링 방법이 연구되고 있다. 최근의 센서기술의 발전, 통신기술, 정보시스템 및 인공지능의 발전은 과거에는 미인식되었던 데이터에서 인지가 가능한 데이터로 추론, 예측, 분류할 수 있게 되었고 새로운 연구분야로 대두되고 있다.

AI 알고리즘을 이용한 혈당 예측에 대한 많은 연구가 있었다. 예를 들면, 인공 채장 프로젝트에서 혈당 수준은 환자의 요구에 맞게 인슐린 흐름을 지속적으로 조절할 수 있도록 예측한다[8]. 많은 연구에도 불구하고 혈당 수준을 정확하게 예측하고 개인화된 혈당 수치를 관리하는 것은 여전히 어렵다. 기존 예측 모델은 인구 기반 예측[9, 10] 또는 환자 기반 예측[11, 12]으로 분류 될 수 있다.

개인의 상황에 대한 인구 기반 예측은 독립적인 인구 데이터를 기반으로 하며, 이 모델의 정확도는 낮다. 환자 기반 예측은 일반적으로 유용한 예측을 위해 많은 양의 과거 환자 데이터를 필요로 하지만 때론 요구사항을 충족할 수 없다.

본 연구는 비침습적 방법으로 인체의 활력 정보인 심박수, 호흡수, 심박출량, 심박변이도의 값을 획득하기 위해 심탄도 센서의 수집되는 데이터를 활용하고, 딥러닝 인공신경망 학습 모델을 이용하여 당뇨 수치를 예측하는 개인화된 데이터 중심 예측 모델을 연구하여 혈당 수치 관리에 불편함과 고통스러움을 개선하고 혈당을 범위 내에서 변동되도록 관리하는데 편리함을 제공하여 개인의 건강관리에 도움이 되고자 한다.

### 1.2 연구목적

논문은 심탄도(BCG, Ballistocardiogram) 센서를 이용하여 생체신호 데이터를 비침습, 무구속적인 방식으로 수집하고, ICT 기술과 고성능 컴퓨팅 환경에서 인공지능 기계학습 알고리즘을 활용하여 데이터 기반 혈당 예측 알고리즘 모형 개발 및 검증하는 방법을 제시하고 연구하는 것이다

## 2. 이론

### 2.1 생체정보 모니터링 기술

심장의 바이탈 모니터링의 중요성과 가정에서의 생체신호 모니터링의 실행 가능성은 지난 20년 동안 생체신호 모니터링을 수행하는 다수의 의료 기기가 개발되고 상용화되고 있다. 전자 장치의 소형화는 생체신호 모니터링 장치 개발에 필수적인 요소로 작용하고 있다.

통신 기술이 발전하면서 인터넷 접속이 가능한 서버시스템과 통신이 가능한 IoT(Internet of Things) 디지털 기기가 개발되고 있다. 디지털 의료기기의 기술은 신규 센서 기술의 발전과 함께 변화되어 질병의 조기 진단, 만성 건강 상태의 예방을 위한 임상 정보 관리를 더 많이 지원하고 있다[13]. 디지털기기 시스템은 데이터를 수집하기 위해 일종의 센서를 통합한 다음 전용 데이터 추출, 분석 및 표현을 수행하기 위한 정보 및 통신 기술을 적용한다.

#### 2.1.1 심장의 전기적 및 기계적 활동

심전도는 심장의 전기적 활동을 기록하는 방법이다. 이 전기적 활동에 해당하는 신호를 심전도 (ECG, Electrocardiogram)라고 한다. 현재 심장 상태의 임상 진단을 위해 가장 널리 사용되는 임상 표준이며, 다양한 형태의 심장병, 특히 부정맥과 급성 심근 경색을 진단 할 수 있는 강력한 도구를 제공한다[14].

심탄도(Ballistocardiogram)는 심장 박출력에 대한 신체의 반응을 측정하며 심혈관 기능을 평가하는 효과적인 비침습적 방법이다. 혈관 구조를 따라 움직이는 혈액은 심장이 뿜 때마다 몸의 질량 중심에 변화를 일으킨다. 전체 운동량을 유지하기 위해 뉴턴의 제 3 법칙의 작용-반작용의 원리에 따라 혈류에 반응하여 신체에서 미세 힘이 생성된다. 심탄도는 심장에서 혈관으로의 혈액 배출에 대한 신체의 움직임에 해당하는 심혈관 신호이다[15]. 신호를 얻는데 사용되는 변환기에 따라 압전의 변화 또는 가속도의 변화로 측정 할 수 있으며 결과 신호 해석의 단위 파형은 Fig.1이다.

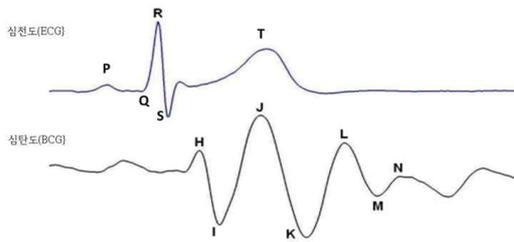


Fig. 1. Unit waveforms in ECG and BCG (head-to-foot direction)[16].

현재 BCG는 하드웨어 기술, 소프트웨어 및 서비스를 포함한 정보 기술 혁명 덕분에 많은 관심을 받고 있다. 압전 폴리비닐리덴 플루오라이드 센서(piezoelectric polyvinylidene fluoride sensors), 전기 기계식 필름 센서(EMFi, electromechanical film sensors), 공압 센서(pneumatic sensors), 로드 셀(load cells), 유압 센서(hydraulic sensors) 및 광섬유 센서(fiber-optic sensors), MEMS 가속도 센서(accelerometer sensor)와 같은 BCG 센서는 의료진 없이도 인공 구조물에 내장 될 수 있는 공산품 형태로 개발되고 있다.

가속도계는 호흡과 심장 박동과 혈류에 의한 신체의 미세한 진동 변화를 포착 할 수 있다. 최근의 BCG센서는 호흡수, 심박수, 심박변이도 및 심박출량 측정이 가능하다[17].

## 2.2 당뇨병과 혈당 모니터링 기술

당뇨병은 전 세계적으로 보편화된 질병으로 초기 증상이 분명하지 않다. 임상적으로 당뇨병을 가진 사람들은 저혈당증, 고혈당증, 고혈당증 혼수 및 케톤산혈증, 동맥 경화증, 고혈압, 뇌혈관 경색증, 당뇨병성 신증, 당뇨병성 망막증, 피부질환 농피증, 습진, 당뇨병성 가려움증, 괴저, 구강질환과 같은 당뇨병 합병증이 있는 경우가 많으며 이는 심각한 건강 문제를 유발할 수 있다[18].

당뇨병 합병증 및 당뇨병 관련 건강 문제의 발생을 줄이기 위해 혈당은 정상 범위(예 : 건강한 사람의 혈당 범위는 70~100 mg/dL, 식후 혈당은 140 mg/dL 이하)에서 관리해야 한다[19].

### 2.2.1 침습적 혈당 모니터링 방법

보편화되어 있는 개인용혈당관리시스템의 혈당측정기의 문제점은 채혈시 고통스럽고 불편하며, 제1형 당뇨의 경우 혈당수준 관리를 위해 하루 최대 3~4회 이상 채혈해야 할 필요가 있다.

혈당수치 측정을 위한 가장 일반적인 검사는 소량의 혈액 샘플을 얻기 위해 란셋 장치로 손가락을 찌르고, 시약 검사스트립에 혈액 한 방울을 침적시키고, 스트립을 측정 장치에 삽입하여 포도당 농도를 확인하는 것이다. 제조업체마다 다른 기술을 사용하지만 대부분의 시스템은 혈액 샘플의 포도당 양에 비례하는 전기적 특성을 측정한다[20].

### 2.2.2 비침습적 혈당 모니터링 방법

비침습적 혈당 모니터링은 일반적으로 포도당 농도 변화에 의해 조절되는 피부와 기저 조직(광학, 열, 마이크로 파 및 전기)의 다양한 물리적 특성을 측정한다.

라만 분광법(Raman spectroscopy)은 광자의 비탄성산란에 기초한 방법으로 단색광이 포도당에 입사할 때, 비탄성충돌로 인한 에너지 전환이 일어나 단색광의 파장과는 다른 파장이 빛이 방사되며 방사광의 스펙트럼을 관측하여 포도당의 농도를 측정하는 방법이다. Lyandres 의 연구[21]에서 표면강화 라만분광 센서(SERS, Raman spectroscopy sensor of surface-enhanced)를 제안했다. 포도당 분자가 다르면 진동이 다를 수 있다. 이 기술은 삼성, 애플의 스마트 손목 시계에 활용되고 있다. 라만분광기 기술은 고정 파장 레이저로 표시된다.

근적외선 분광법은 780-2500nm의 근적외선을 광원으로 사용한다[22, 23]. 광원은 혈액 성분과 상호 작용할

수 있으며 산란, 흡수 및 반사 될 수 있다. 수신되는 광의 강도는 Beer-Lambert 법칙에 따라 포도당 농도에 의해 달라지며, 수치를 추정 할 수 있다.

생체 임피던스 분광법은 포도당 농도의 변화에 의한 나트륨 이온과 칼륨 이온 농도의 변화로 세포막 전위차가 변경된다. 따라서, 인체의 포도당 값을 예측하는 유전 값이 변경되어 피부를 통한 유전 특성을 측정하는 방법이다[24].

### 3. 연구방법

#### 3.1 연구대상

본 연구에서 필요한 데이터를 획득하기 위한 연구대상자는 의학적으로 특별한 병력이 없는 20대에서 60대의 성인 99명을 대상으로 하였다. 연구대상자는 연구의 목적, 데이터 수집 정보, 소요 시간 등을 설명한 후 자발적 지원 방식으로 모집하였고, 기관생명윤리위원회의 심의(SM-202103-012-2)와 연구윤리를 준수하였다.

#### 3.2 데이터 수집기간

연구에 필요한 데이터 수집은 2021년 4월에서 2021년 5월 기간에 수행하였다.

비침습적 인공지능 알고리즘을 활용한 혈당예측 모델 개발을 위한 기초 데이터는 심박동의 정보를 획득하는 BCG 센서와 혈당수치 정보 수집을 위해 개인용혈당관리 시스템의 혈당 수치와 나이와 성별을 사용하였다. BCG 센서 데이터는 1Hz 간격으로 수집된다.

#### 3.3 연구도구

연구 도구는 병원용 침대, 용량형 MEMS BCG센서, 개인용혈당관리시스템, 통신장비 및 컴퓨팅 시스템을 이용하였다.

##### 3.3.1 심탄도 센서

생체 정보를 수집하기 위해 공산품으로 구입이 가능한 용량형 MEMS BCG 센서를 이용하였다. BCG 센서 모델은 SCA11H이며, 제조사는 Murata이다. 센서 기본사양은 Table 1과 같다. SCA11H는 센서, 마이크로 컨트롤러(MCU) 및 Wi-Fi 송수신기로 구성된 생체신호 수집 장치이다. BCG센서는 병원용 침대 프레임에 부착하여 사용하였다[Fig.2 참조].

Table 1. BCG Sensor Specifications[25]

Attribute	Attribute Value
Sensing Axis	1-Axis
Acceleration measurement range	$\pm 0.5 \text{ g}, \pm 1 \text{ g}$
Sensitivity	427 LSB/g
RF Interface Type	IEEE802.11 b/g/n(Wi-Fi)
interface	UART
Operating Supply Voltage	DC $9\pm 0.5\text{V}$
output	1 Hz output rate
Pulse detection range	40 - 120 bpm



Fig. 2. Hospital bed with BCG sensor

##### 3.3.2 개인용혈당관리시스템

혈당 수치 정보를 수집하기 위해 국제 혈당측정기 정확도 기준(ISO 15197:2013) 요구에 부합되는 혈당측정기를 사용하였다. 개인용혈당측정시스템은 자가혈을 채취하여 혈액 내 포도당(glucose)의 양을 측정하기 위한 진단기기로 당뇨 질환자를 비롯하여 누구나 의료진의 도움 없이 측정이 가능하다[26]. 연구에 사용된 개인용혈당 관리시스템의 사양은 Table 2와 같다.

Table 2. Blood glucose meter specifications (Roche, Accu-chek® Instant)[27]

Attribute	attribute value
ISO Compliance	Accu-Chek Instant system fully conforms to the requirements of EN ISO 15197:2015 & ISO 15197:2013
Enzyme system	FAD glucose dehydrogenase (GDH), electrochemical
Sample size	0.6 $\mu$ L
Blood Sample Types	Capillary, venous, arterial, neonatal
Measurement range	0.6-33.3 mmol/L, 10.8-599.4 mg/mL
Measurement time	< 4 Seconds
Memory capacity	Memory can store 720 tests including 7, 14, 30 & 90 day averages.
Haematocrit range	10-65%
battery	3V lithium battery, 2pcs (Model: CR2032)
Display	Backlit LCD
size	77.1x 48.6 x 15.3mm (length x width x height)
weight	Approximately 40 g (with batteries)

### 3.3.3 통신장비

WiFi 통신환경을 구성하기 위해 TP-Link AC1750(Archer C7) 모델을 사용하였다.

### 3.3.4 컴퓨팅 시스템

컴퓨팅 시스템은 센서에서 송신되는 데이터를 연속적으로 수집하고 저장관리한다. 데이터 저장 관리는 RDBMS(MySQL 6.4)을 사용하였다. 컴퓨팅 시스템의 장치 사양은 Table 3과 같다.

Table 3. Computing system specifications

Type	Description
CPU	Intel(R) Core(TM) i7-9700K
Clock rate	3.60Hz
GPU	AMD Radeon RX 5700 XT
GPU Memory	8GB GDDR6 1759 MHz
RAM(memory)	16GB
OS	Windows 10 Pro. 1903. 64bit

## 3.4 데이터 수집

연구에 사용되는 정보는 연령, 성별, 심박수, 심박변이도, 호흡수, 심박출량, 당뇨 유무이다. 측정 센서는 제어 및 계산 로직을 통해 심박수(HR), 호흡수(RR), 박출량(SV), 심박변이도(HRV) 데이터를 수집한다.

### 3.4.1 데이터 수집 구성 및 방법

데이터 수집을 위한 구성도는 Fig.3이다. 측정부 센서는 인체의 생체 정보를 수집한다. 센서는 SCA11H를 사용하였으며 데이터는 수집 및 분석용 컴퓨팅 시스템으로 전송된다. 컴퓨팅 시스템은 인터넷 표준 프로토콜인 TCP/IP 기반으로 센서에서 연속적으로 전송되는 데이터를 수집, 분류, 저장한다. 그리고 데이터는 분석하기 위해 데이터 전처리, 기계학습, 인공지능 신경망 알고리즘 등을 응용하여 분류 및 예측을 수행한다. 측정부의 센서를 통해 수집되는 주요 정보는 HR, RR, SV, HRV, 침대 점유상태 등이다.



Fig. 3. Data collection diagram

데이터 수집프로세스는 다음과 같다.

- ① 연구대상자는 신체적으로 안정된 상태에서 병원용 침대에 양와위 자세로 눕는다.
- ② 병원용 침대에 부착되어 있는 심탄도 센서를 이용하여 5분 동안 생체신호 데이터를 수집하여 컴퓨팅 시스템에 전송한다.
- ③ 그 이후 연구대상자는 개인용혈당관리시스템을 이용하여 손끝을 직접 점혈하고 혈당기(Table 2)를 이용하여 혈당수치를 확인하고 기록한다.
- ④ 나이와 성별을 기록한다.

### 3.4.2 센서 신호 처리 및 계산

심탄도센서의 가속도 측정 세기는 0.5g(gravity, 중력 가속도)이다. 심탄도는 아날로그 신호를 디지털 값을 변환하기 위해 Table 4의 계산식이 적용된다. 심박수 값은 아날로그 신호의 10초간 평균의 연속적인 값이며, 진폭의 세기를 측정하여 호흡수의 변화를 계산 한다.

Table 4. BCG 신호처리 계산식[28].

Variable	Equation	Units
time interval between beat-to-beat	$tb2b_{(n)} = t_n - t_{n-1}$	msec
Heart Rate	$HR = Avg_{10sec}(60000/tb2b_{(n)})$	1/min
Heart Rate Variability	$HRV = Avg_{10sec} *  tb2b_{(n+1)} - tb2b_{(n)} $	msec
Stroke Volume	$SV = Avg_{10sec} (A_{n-1}, A_n, A_{n+1}, \dots)$	a.u.
Respiration Rate	$RR = (60000 / t_{r2r})$ $t_{r2r} = F(t_{r2r(1)}, t_{r2r(2)})$ $t_{r2r(n)} = t(\max A)_m - t(\max A)_{m-1}$	1/min

### 3.4.3 HRV의 시계열 계산

혈당수치 예측 모델 개발을 위해 BCG 센서의 심박수(HR), 심박변이도(HRV), 호흡수(RR), 심박출량(SV)과 HRV를 이용하여 시계열 정보인 SDNN, RMSSD, PNN50 값을 계산하여 인공지능 기계학습의 입력 변수로 사용하였다. 그리고 나이, 성별, 혈당 수치 값을 이용하였다.

### 3.4.4 센서 수집데이터의 신뢰성

디지털 센서를 통해 수집된 데이터의 신뢰성은 심전도(ECG)의 심박수 정보와 비교하여 검증한 결과 발표가 있었다. Sami Nurmi의 연구에서는 BCG 심박수와 수면다원검사(PSG)의 심박수와 비교했으며[29], 심박수(HR)의 경우 BCG와 PSG간에 측정된 차이는  $-0.1 \pm 4.4$  BPM이었으며 상관 관계는 30분 평균 97%로 발표하였다(Fig.4).

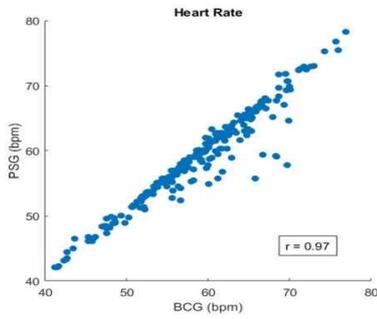


Fig. 4. Correlation between BCG heart rate and PSG heart rate during sleep[29].

최상기, 이거룡의 연구에 의하면 심전도(ECG)와 심탄도(BCG)의 심박수 상관 관계를 선형회귀 분석한 결과는 선형적인 상관 관계가 있으며, 결정 계수는  $R^2=0.959$  ( $P < .05$ )로 높은 상관 관계가 있음을 발표하였다(Fig.5)[30].

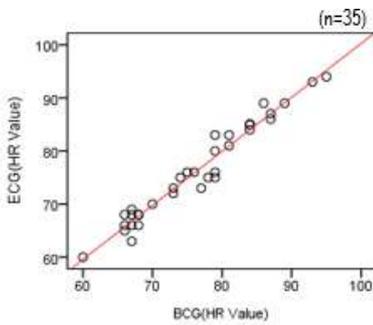


Fig. 5. Scatter of Heart Rate in ECG and BCG

### 3.5 분석방법

심탄도 센서에서 수집된 정보는 SPSS(Version 23, IBM, USA)를 이용하여 데이터의 기본 통계분석과 상관 분석을 실시하였으며, 혈당수치 예측을 위해 파이썬(Python) 프로그램을 이용하였다. 혈당 예측 기계학습은 구글의 딥러닝 프레임워크 Tensorflow와 파이썬 3.7을 사용하여 인공지능 알고리즘을 구현하였다. 사용한 프로그램 도구는 Keras, Pandas, Matplotlib 등을 이용하였다. 예측 데이터는 측정된 원시 데이터와 맵핑하고 Clarke EGA(Error Grid Analysis)를 사용하여 도시화하였다.

#### 3.5.1 데이터 전처리

데이터 분석에서 다음의 경우는 데이터를 제거하였다.

##### 1) 이상치 검출

BCG 센서의 이상치는 검출하고 제거하였다. HR값이 0이면 제거하였다.

##### 2) 결측값 처리

결측값은 제거하였다. 침대 점유상태가 빈침대 상태의 숫자 0, 이동상태의 숫자 2인 경우는 데이터는 결측처리하였다. 침대 점유 상태의 값이 숫자 1인 정보만 선별하였다.

##### 3) 중복값 처리

연속된 신호의 수집은 중복된 데이터가 발생할 수 있다. 연속적인 신호레코드 동일하게 수집되는 경우는 1개의 데이터 레코드만 선택하고 나머지 레코드는 제거하였다.

#### 3.5.2 회귀 평가지표

회귀 예측의 평가 지표는 실제 값과 회귀 예측값의 차이로 평가한다. 회귀 평가지표에 적용된 MAE, MSE, RMSE, MSLE, RMSLE는 값이 작을수록 회귀 예측 성능이 우수하며 값이 작을수록 예측값과 실제값의 차이가 없다고 해석할 수 있다. 반면 결정계수(coefficient of determination,  $R^2$ )는 1에 가까운 값이 성능이 우수하다. 선형 회귀에서는 비용함수로 MSE(Mean Square Error)를 주로 사용한다.

##### 1) 평균 절대 오차 (MAE, Mean Absolute Error)

실제 값과 예측 값의 차이를 절대값으로 변환해 평균을 구한 값이다

##### 2) 평균 제곱 오차 (MSE, Mean Squared Error)

실제 값과 예측 값의 차이를 제곱해 평균을 구한 값이다. 선형회귀에서는 비용함수로 MSE(Mean Square Error)를 주로 사용한다.

##### 3) 평균 제곱근 오차 (RMSE, Root Mean Squared Error)

MSE 값은 오류의 제곱을 구하므로 실제 오류 평균보다 더 커지는 특성이 있으므로 MSE에 루트 값을 구한 RMSE 값을 사용한다.

##### 4) 결정계수( $R^2$ )

결정계수( $R^2$ )는 분산 기반으로 예측 성능을 평가한다. 값이 1에 가까울수록 예측 정확도가 높다.

#### 3.5.3 Clarke error grid

현재 혈당 센서의 정확도를 결정하는데 사용되는 두 가지 프로토콜이 있다. 하나는 국제 표준화기구(ISO)에 의한 규제(ISO 15197:2013)이고 다른 하나는 Clarke error grid 이다. ISO는 체외 혈당 센서는 75 mg/dL 이

상의 혈당 농도를 감지 할 수 있어야 하며 측정 값의 95%가 기준 기기의  $\pm 20\%$  내에 있어야 한다고 규제하고 있다. 75 mg/dL 미만의 혈당 농도의 경우 모든 측정값이  $\pm 15$  mg/dL) 이내이다. 1987년 Clarke[31]가 제시한 “오류 그리드”는 센서 장치를 통해 측정된 값과 참조한 혈당 농도와 매칭하여 표시한 도표이다(Fig.6).

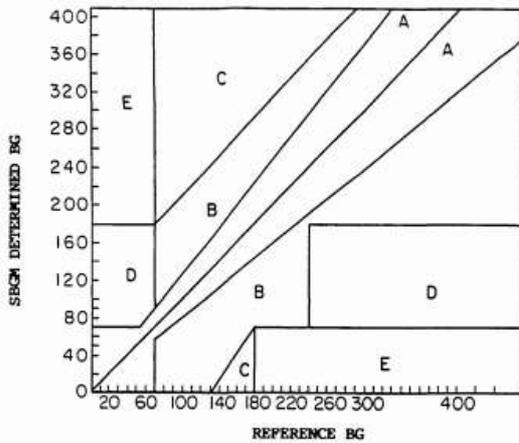


Fig. 6. Clarke error grid.

### 3.6 예측모델 개발

혈당수치 예측 모델은 심혈관 질환이 없는 사지가 모두 정상인의 심박동수와 호흡의 영향으로 발생하는 대혈관의 혈류 변화와 심박출에 의해 발생하는 반동력의 변화를 측정하는 심탄도 센서의 측정데이터와 딥러닝 계산 알고리즘을 이용하여 혈당 수치를 예측하는 모델이다. 예측 모델 개발에 필요한 데이터를 수집하기 위해 지원자 99명에서 수집한 데이터를 기반으로 혈당 예측 모델을 모델링하였다.

혈당 수치 예측은 선형 회귀를 선택하였다. 선형 회귀는 스칼라 종속 변수 혈당과 독립변수 간의 관계를 모델링 할 수 있다.

혈당 예측 알고리즘 개발에서 가장 일반적인 과제는 적절한 데이터셋을 만드는 것이다. 예측 알고리즘에서 사용한 데이터는 용량형 MEMS 가속도계 센서를 이용한 심탄도센서를 이용하여 정상인의 생체정보(심박수, 심박변이도, 심박출량, 호흡수)를 획득한다. 그리고 개인용혈당관리시스템을 이용하여 혈당 수치를 기준 값으로 활용하기 위해 수집하여 혈당 수치 예측을 위한 데이터 셋과 기계학습을 모델링하였다. 딥러닝 예측 모형 및 결과의 정확도를 파악하기 위해 수집된 데이터를 무작위로 추출하여 혈당수치를 비교·검증하였다(Fig.7).

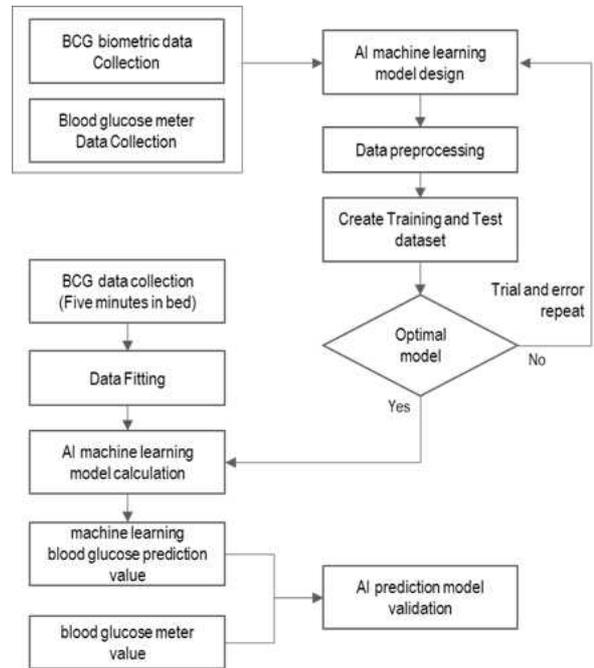


Fig. 7. Blood glucose prediction model and validation process

## 4. 연구결과 및 고찰

### 4.1 연구대상자 일반적 특성 및 분석

#### 4.1.1 연구대상자 특성

Table 5. BCG data age distribution

	Age Group	Male (n=67)	Female (n=32)	M	SD
T2DM- (n=43)	20	7	2	44.95	14.48
	30	5	3		
	40	4	2		
	50	8	6		
	60	5	1		
T2DM+ (n=56)	20	3	0	52.91	11.16
	30	1	3		
	40	9	2		
	50	15	4		
	60	10	9		

\*T2DM- : Normal group

\*T2DM+ : Type 2 diabetes group (not diagnosed)

혈당 예측을 위한 심탄도 데이터 수집 대상자는 99명이다. 의학적 병력이 없는 정상인(T2DM-)은 43명, 혈당수치가 126 mg/dL이상(DM+)은 56명이며 연령 분포는 21세에서 68세 사이에 분포한다. 심탄도 데이터 수집 대

상자의 통계 정보는 Table 5이다. 개인용 혈당관리시스템의 혈당수치가 126 mg/dL 이상을 당뇨 그룹(T2DM+)으로 분류하였으며, 분류 대상자는 56명이다.

4.1.2 데이터 평가

심탄도 수집 데이터의 유의성을 검증하고 당뇨(T2DM+) 유무를 그룹으로 분류하여 두 그룹의 평균값 차이를 분석하였다. Wilcoxon signed rank test 분석 결과는 Table 6과 같다. 수집 데이터 수는 총 9,786(T2DM- = 4,733 ; T2DM+ = 5,053) 레코드이며, 유의 수준은 95%이다. T2DM+로 분류한 기준은 혈당 수치가 126 mg/dL 이상이다.

Table 6. Statistical analysis result

variable	T2DM- (M±SD)	T2DM+ (M±SD)	P-Value
HR	71.83±13.03	76.71±13.22	<.0001
RR	10.89±3.97	11.36±5.07	<.0001
SV	44.30±13.42	46.36±13.24	<.0001
HRV	113.96±75.69	97.21±67.76	<.0001
SDNN	43.65±15.78	34.26±16.50	<.0001
RMSSD	17.98±5.06	15.96±5.64	<.0001
PNN50	0.03±0.03	0.02±0.02	<.0001

통계적으로 두 그룹 간의 평균 차이의 분석 결과는 정상(T2DM-)과 당뇨(T2DM+) 그룹 간의 HRV값은 유의한 차이(p<.0001)가 있고, 정상 그룹의 HRV 평균값이 113.96 으로 당뇨그룹보다 16.75 만큼 HRV값이 높게 나타났다. 정상(T2DM-)과 당뇨(T2DM+) 그룹 간의 HR(심박수) 값은 유의한 차이(p<0.0001)가 있으며, 정상 HR의 평균이 71.83로 당뇨그룹 보다 4.88만큼 HR 값이 낮게 나타났다.

Benichou 연구에 의하면 제2형 당뇨병이 심박수 변동성을 체계적으로 검토 분석한 보고서에서 DM 환자에서 HRV의 전반적인 감소가 있다는 발표가 있었으며, 심탄도 센서를 이용한 수집한 HRV값을 이용하여 분석한 결과도 동일함을 추론할 수 있었다[32].

Minato 연구에 의하면 대사증후군(Metabolic Syndrome)이 있는 제2형 당뇨병(T2DM+) 환자(n=77)는 대사증후군이 없는 환자에 비해 전혈 점도(WBV, Whole Blood Viscosity)가 더 높은 것으로 보고 하였으며[33] Ahn의 연구 보고서에 의하면 적혈구의 응집(aggregation) 증가와 변형능(deformability)의 감퇴와 이에 따른 혈액 점도의 증가와 말초혈관 유동저항

(peripheral flow resistance)이 증가 된다고 하였다 [34]. 또한 고혈당에 의한 당화혈색소 증가는 적혈구 간의 비특이적 결합을 증가시키고 적혈구의 연전형성은 적혈구의 흐름을 방해하고 혈액의 점성을 증가시킨다. 이러한 혈유변학적 요인은 심혈관의 혈액 흐름에 영향이 있음을 추론할 수 있으며, 심박변이도(HRV)는 고혈당에 의한 영향을 받고 있음을 시사한다.

4.1.3 변인별 상관관계 평가

BCG 센서를 통해 수집된 BCG 데이터셋의 생체 정보들의 관계 강도나 관련성 정도와 방향을 분석하기 위해 각 변인별 피어슨 상관관계를 분석하였다. 피어슨 상관관계 분석결과는 Table 7와 같다.

Table 7. Correlation matrix for BCG data variables

(N=9,786)							
	gender	age	HR	HRV	SV	RR	BG
gender	1						
age	-.010	1					
HR	-.189**	.079**	1				
HRV	-.118**	.069**	-.178**	1			
SV	-.231**	.069**	-.025**	.527**	1		
RR	-.057**	-.055**	.150**	-.376**	-.066**	1	
BG	-.132**	.384**	.164**	-.019**	-.060**	.100**	1

- \*\*P < 0.01
- HR : Heart Rate, 심장 박동수
- RR : Respiration Rate, 호흡수
- SV : relative Stroke Volume, 심박출량
- HRV : Heart Rate Variability, 심박변이도
- BG : Blood Glucose, 혈당

Table 7은 BCG 수집데이터의 변인들에 대한 상관행렬표이다. BCG 수집데이터의 변인들 간의 상관은 정적 상관관계를 보였다. 이들의 상관계수는 전체적으로 0.384에서 -0.132로 유의수준은 P<0.01에서 통계적으로 검증되었다.

4.2 혈당수치 예측모델 설계

혈당수치 예측모델을 구현하기 위해 본 연구에서 다변량 선형 회귀 모델(multivariate linear regression)과 딥러닝 신경망(Deep Learning ANN)을 이용하여 모델을 설계하였다.

데이터셋은 BCG센서에서 획득한 심박수, 호흡수, 심박출량, 심박변이도와 개인용혈당관리시스템을 이용한 혈당 수치 및 나이와 성별을 라벨링하여 입력노드로 사

용하였다. 연구대상자별로 HRV를 이용하여 시계열 정보인 SDNN, RMSSD, PNN50 값을 구하여 라벨링하였다. 데이터는 침대점유 상태 값인 1인 경우만 선택하고 나머지 데이터는 제외하였다. 데이터는 학습용과 검증용 셋으로 분할된다. 학습용은 전체 데이터셋의 75 %로 설정하였으며, 검증용은 나머지 25 %이다. 예측 효율성을 향상시키기 위해 scaling 방법을 적용하여 정규화 작업을 하였다.

### 4.3 구현 및 결과

#### 4.3.1 다층 퍼셉트론 모델 (Multilayer Perceptron Model)

모델의 명확성과 지도 학습 및 분류 문제에 대한 잘 문서화된 우수한 성능을 고려하여 딥러닝 아키텍처로 MLP를 적용하였다. 구현된 아키텍처의 개념도는 Fig.8 이다.

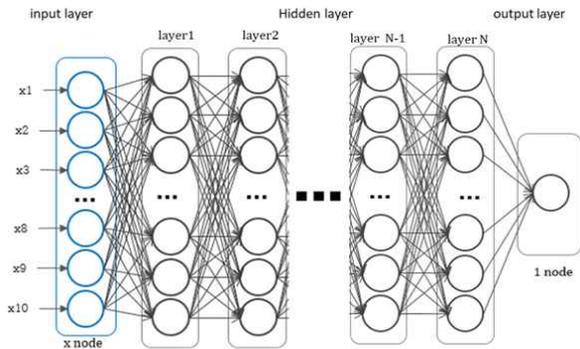


Fig. 8. MLP architecture

MLP 신경망은 1 개의 입력층, 7개의 은닉층 및 1 개의 출력층으로 구성된다. 입력층에는 라벨링된 데이터를 의미하며 10개의 노드를 사용하였다. 입력층의 네트워크 전달값은 각각 64, 128, 192, 256, 320, 386, 512의 노드가 있는 7개의 은닉층로 전달된다. 마지막으로 전달된 값은 혈당 수치 예측 노드로 구성된 출력층으로 수렴된다.

##### 4.3.1.1 구성 및 하이퍼파라미터

모델의 하이퍼파라미터 구성은 모든 딥러닝 모델 연구에서 가장 중요한 작업 중 하나이다. TensorFlow에서 예측을 위한 모델은 keras.models, keras.layers 및 keras.optimizers 라이브러리 사용하여 컴파일된다. 이미 제시된 층 구성 외에도 Table 8에는 MLP(Multilayer Perceptron)에 대해 선택된 다른 하이퍼파라미터를 표

시하였다.

Table 8. Hyperparameters

property	method
Weight Initialization	Normal
Activation Functions	ReLU, Linear
Optimizaton(updater)	ADAM
Backporpagation	True
Backpropagation Method	Mini-batch, gradient descent
Mini-batch	64
Loss Function	msle
Regularization	true
Number of epochs	120

#### 4.3.2 실험

##### 4.3.2.1 은닉층 수에 의한 영향 분석

모델의 예측 정확도와 측정된 값과 예측된 값 사이의 편차를 평가하기 위해 MSE, MAE, RMSE, 결정계수( $R^2$ ) 값을 확인하였다. 혈당 수치 예측 데이터를 분석하기 위해 Clarke Error Grid Analysis를 이용하여 그래픽으로 표시하였다[Fig.9][35].

하이퍼 파라미터를 변경하면서 모델을 반복적으로 구성하고 학습시켰다. 개인용혈당관리시스템으로 측정된 혈당수치와 구현된 예측모델을 통하여 예측된 혈당수치의 결정계수( $R^2$ )를 구하였다. 최적의 예측 모델에서 결정계수( $R^2$ )의 값은 1이다. 1에 근접할수록 예측 모형의 정확도는 매우 높다고 해석 할 수 있다.

Table 9. Prediction and performance Results in MLP

number of hidden layers		5 times Average			
		MAE	MSE	RMSE	$R^2$
H4	Learn	0.5796	0.7699	0.8681	
	Valid	0.6151	0.9162	0.9482	0.9996
H5	Learn	0.5405	0.6193	0.7763	
	Valid	0.5734	0.7193	0.8382	0.9997
H6	Learn	0.5150	0.7026	0.8263	
	Valid	0.5329	0.7461	0.8510	0.9997
H7	Learn	0.5226	0.6328	0.7692	
	Valid	0.5408	0.6776	0.7968	0.9997
H8	Learn	0.5752	0.8652	0.8885	
	Valid	0.6103	1.0021	0.9533	0.9996

Table 9는 MLP 모델 개발에 사용되는 은닉층에 대한 예측 성능을 정리한 내용이다. MLP 모델의 예측 성능은 은닉층 개수별로 각각 5회 수행한 평균 값이다. 사용한

입력노드 값은 HR, SV, RR, HRV, SDNN, RMSSD, PNN50, 나이, 성별이다. 은닉층 7개를 사용한 MLP 아키텍처를 사용한 설계모형의 딥러닝 알고리즘에서 최적의 성능을 보였다. 최적 성능을 보인 은닉층 7개를 사용한 MLP 아키텍처 구조를 적용하여 5회 실험한 학습데이터의 평균 MSE, MAE 및 RMSE 수치는 각각 0.5226, 0.6328 및 0.7692이며 검증데이터 평균 수치는 각각 0.5408, 0.6776, 0.7968이었으며, 결정계수(R<sup>2</sup>) 수치는 0.9997의 결과를 보였다. 최적 성능을 보인 학습데이터의 MSE, MAE 및 RMSE 수치는 각각 0.3715, 0.3891 및 0.6237이며 검증데이터는 각각 0.3717, 0.3785, 0.6152이었으며, 결정계수(R<sup>2</sup>) 수치는 0.9998이었다.

[Fig.9]은 다층퍼셉트론(MLP)을 이용한 딥러닝 혈당 수치 예측 모델의 예측값과 개인용혈당관리시스템의 실측값 간의 비교를 보여주는 그래프이다. 예측 수치를 Clarke EGA(Error Grid Analysis) 도표에서 실측값과 예측값의 쌍을 그래프로 표시한 결과이며 “A”영역에 분포한 확률은 100%로 나타났다. x축은 개인용혈당관리시스템의 전자혈당기의 실측값이며 y축은 인공지능 딥러닝 예측모형을 이용한 혈당 수치 예측값이다.

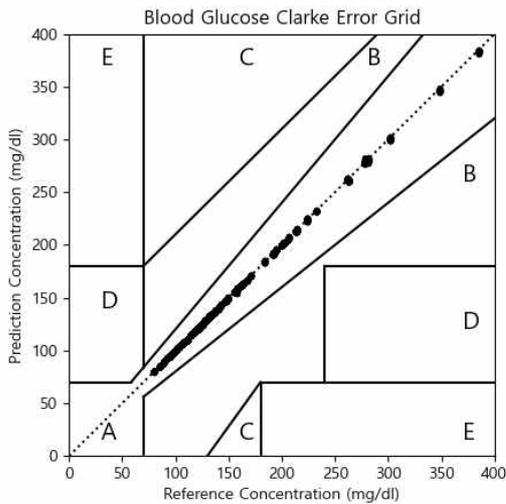


Fig. 9. Clarke Error Grid Analysis Result of Predictive Model (at H7 Model)

Clarke EGA(Error Grid Analysis)에서 도표한 쌍은 임상적으로 정확한 것으로 간주되며 차이가 20% 이하인 경우 (혈당 값이 70 mg/mL 이상인 경우) 구역 A에 배치된다. 구역 B에는 불일치가 20% 이상인 쌍이 포함되지만 예상되는 부작용은 없다. 구역 C의 불일치로 인해 치료 오류가 발생할 수 있지만 임상 결과에 대한 위험은

낮다. 구역 D의 불일치는 치료에 의한 잘못된 결과로 이어질 수 있는 반면 구역 E는 부적절한 치료 가능성을 나타낸다.

4.3.2.2 혈당수치 예측에 영향을 주는 변인 분석

생체정보에서 혈당에 영향을 받고 있는 생리적 정보를 추론하기 위해 디지털기기에서 수집된 라벨링된 변인을 변경하면서 혈당수치 예측 가능성을 확인하였다. 라벨링된 변인의 영향도를 파악하기 위해 예측 모형에 입력되는 입력노드를 구분하였다. 입력노드 설계는 Table 10에서 설명한다.

Table 10. Input node group for verifying variables that affect the predictive model

node	Labeling variables	purpose
EP1	HR, SV, RR, HRV	Check the influence of HR, SV, RR, and HRV variables in the predictive model
EP2	HR, SV, RR, HRV, gender, age	Check the influence of HR, SV, RR, HRV, gender, and age in the predictive model
EP3	HRV, SDNN, RMSSD, PNN50, gender, age	Check the influence of HRV, SDNN, RMSSD, PNN50, gender and age in the predictive model
EP4	HRV, SDNN, RMSSD, PNN50, age	Check the influence of HRV, SDNN, RMSSD, PNN50 and age in the predictive model
EP5	HRV, SDNN, RMSSD, PNN50, gender	Check the influence of HRV, SDNN, RMSSD, PNN50 and gender in the predictive model
EP6	HRV, SDNN, RMSSD, PNN50	Check the influence of HRV, SDNN, RMSSD, and PNN50 in the predictive model

Table 11. Blood Glucose level predictive performance results by input node

Input node		5 times Average			
		MAE	MSE	RMSE	R <sup>2</sup>
EP1	Learn	19.60418	1066.1827	32.6304	
	Valid	22.7392	1441.2547	37.9518	0.4722
EP2	Learn	5.4949	127.4955	11.2102	
	Valid	6.6319	212.8921	14.5501	0.9220
EP3	Learn	2.3229	26.4907	3.5355	
	Valid	2.3634	27.2337	3.5917	0.9900
EP4	Learn	0.9272	2.1382	1.3571	
	Valid	0.9492	2.3238	1.4175	0.9991
EP5	Learn	2.7399	39.0014	4.4516	
	Valid	2.8479	44.4533	4.7198	0.9837
EP6	Learn	3.3639	47.3397	5.7787	
	Valid	3.4765	52.2783	6.0730	0.9808

혈당수치 예측 모델에서 입력노드에 의한 혈당 수치 예측 성능을 비교한 결과는 Table 11에 정리하였다. Table 11의 입력 노드별 딥러닝 학습결과를 보면 “EP4”인 HRV, SDNN, RMSSD, PNN50 및 나이 변수를 적용하여 5회 실험한 학습 데이터에 대한 평균 MSE, MAE 및 RMSE는 각각 0.9272, 2.1382, 1.3571이며 검증데이터 평균은 각각 0.9492, 2.3238, 1.4175 이었고, 검증데이터의 결정계수( $R^2$ )는 0.9991로 다른 비교군 입력노드에 비해 가장 우수하였다(Fig 10).

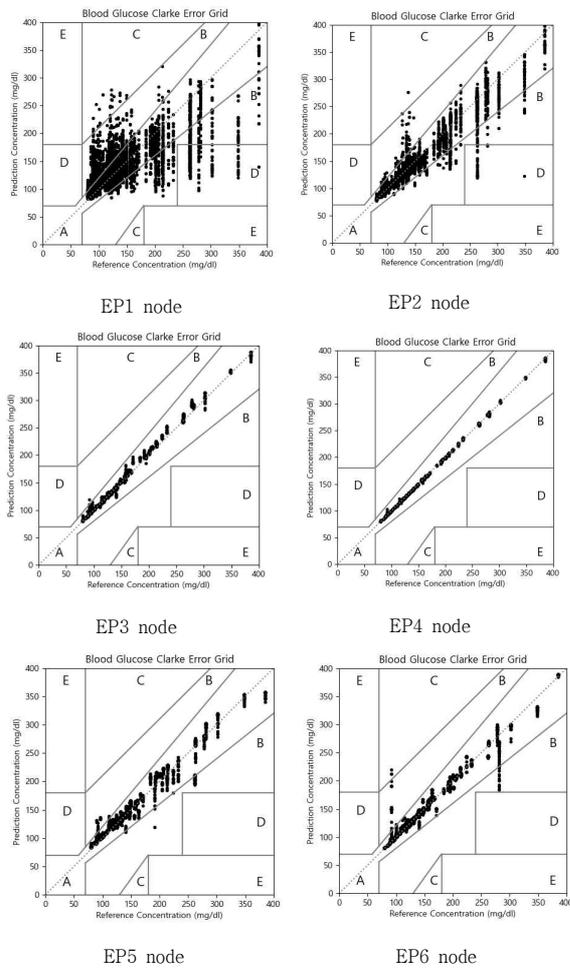


Fig. 10. Clarke Error Grid Analysis Results by Input Node

### 4.3.3 결과 고찰 및 한계

#### 4.3.3.1 혈당수치 예측 결과

연구 결과는 혈당 수치 예측에 영향을 미치는 입력노드는 HRV, SDNN, RMSSD, PNN50 및 나이이며, MLP 아키텍처의 7개 층으로 구성된 예측 모형과 HR, SV, RR, HRV, SDNN, RMSSD, PNN50, 나이, 성별의 입력

노드를 적용하면 혈당수치 예측이 가능할 수 있음을 의미한다. 그리고, 인공지능 알고리즘의 회귀 예측 모형의 실험 결과는 측정 데이터와 예측데이터를 비교한 예측 정확도는 결정계수( $R^2$ )로 확인하였으며 0.9997의 결과를 보였다.

혈당 관리를 위해 매번 채혈을 위한 점혈의 고통이 없고 비침습적 방법으로 혈당수치 예측 가능성을 검증한 실험 결과는 심박동에 의해 나타나는 물리적인 힘의 변화 값인 BCG 데이터와 인공지능 기계학습을 융합하여 혈당수치 예측 모델 개발 가능성을 검증할 수 있었으며, 심박동의 데이터를 기반으로 혈당 수치를 예측할 수 있을 것으로 사료된다.

#### 4.3.3.2 연구의 한계

연구는 개인용혈당관리시스템의 혈당측정기에서 측정된 혈당 수치를 참고 기준으로 이용하였으며 학습모델에서 사용된 혈당 수치 범위는 80 - 385 mg/dL의 범위이다. 연령대는 20대에서 60대의 정상인의 데이터를 이용하였다. 그러므로 혈당수치가 80 mg/dL 이하와 385 mg/dL 이상인 경우 예측모형에 대한 검증은 수행되지 않았다. 또한 20세 이하 70대 이상의 연령대에 대한 예측 모델 검증도 수행되지 않았다.

기계학습을 이용한 혈당수치 예측 연구는 있었으나 심탄도 센서에서 수집한 데이터를 이용한 혈당수치 예측 연구는 현재까진 없었다.

## 5. 결론

연구의 목적은 인체의 심박동과 호흡의 변화를 측정할 수 있는 심탄도 센서를 이용하여 데이터를 수집하고 데이터 전처리 후 인공지능 딥러닝기반 혈당수치 예측 모델을 연구하였다. 그리고 데이터 기반 혈당 예측에 필요한 입력 변인이 무엇인지 파악하기 위한 연구를 수행하였다.

딥러닝 인공신경망을 이용한 혈당수치 예측 결과는 HR, SV, RR, HRV, SDNN, RMSSD, PNN50, 나이 및 성별의 입력 노드와 MLP 아키텍처를 적용하였으며 은닉층 7개를 사용한 예측 모델에서 최적의 결과를 제공하였다.

생활 습관의 변화가 필요한 만성 질환인 당뇨병은 혈당의 지속적인 조절과 혈당 관리가 건강한 삶을 유지하기 위해 필요하다. 센서기술과 인공지능 기술이 융합된 혈당 예측모델은 데이터 수집, 데이터 변환 및 인공지능

기계학습 예측모델 활용 등의 일련의 프로세스를 통해 무의미한 데이터를 의학적으로 의미있는 정보로 활용할 수 있으며, 심박동의 변화 데이터를 기반한 혈당 수치 예측에 활용될 수 있는 가능성을 확인할 수 있었다.

심박수(HR), 심박변이도(HRV), 심박출량(SV), 호흡수(RR), HRV의 시계열정보인 SDNN, RMSSD 및 PNN50 등의 데이터를 기반으로 한 혈당수치를 예측하는 모델을 표준화하고 데이터셋 수집과 예측 정확성을 검증하는 연구가 계속적으로 진행된다면 혈당 모니터링을 고통없이 비채혈식의 혈당 수준 관리에 활용될 수 있을 것으로 사료된다.

## REFERENCES

- [1] KyungHee University Medical Center (2021.07.25). *Medical Commons:Diabetes*. [https://www.khuh.or.kr/04/01.php?hospitalpath=md&table=mdlecture&page=1&command=view\\_article&key=262&s\\_key=&keycode=&keycode=](https://www.khuh.or.kr/04/01.php?hospitalpath=md&table=mdlecture&page=1&command=view_article&key=262&s_key=&keycode=&keycode=)
- [2] Ruth S Weinstock. (2021.05.20). *Patient education: Blood glucose monitoring in diabetes (Beyond the Basics)*. <https://www.uptodate.com/contents/blood-glucose-monitoring-in-diabetes-beyond-the-basics>
- [3] Wolfsdorf, Joseph & Glaser, Nicole & Agus, Michael & Fritsch, Maria & Hanas, Ragnar & Rewers, Arleta & Sperling, Mark & Codner, Ethel. (2018). Diabetic Ketoacidosis and Hyperglycemic Hyperosmolar State: A Consensus Statement from the International Society for Pediatric and Adolescent Diabetes. *Pediatric Diabetes*. 19 Suppl 27. DOI : 10.1111/pedi.12701.
- [4] Yanggyo Kang. (2019). Glucose Management Using Continuous Glucose Monitors. *J Korean Diabetes* 2019;20:42-46. DOI : 10.4093/jkd.2019.20.1.42
- [5] Korean Diabetes Association. (2016.03.23). *2015 Treatment Guidelines for Diabetes*. Gold Planning. Seoul. <https://www.diabetes.or.kr>
- [6] Ganz, T., Wainstein, J., Gilad, S., Limor, R., Boaz, M., & Stern, N. (2017). Serum asymmetric dimethylarginine and arginine levels predict microvascular and macrovascular complications in type 2 diabetes mellitus. *Diabetes/metabolism research and reviews*, 33(2), DOI : 10.1002/dmrr.2836
- [7] American Diabetes Association. (2009). Diagnosis and Classification of Diabetes Mellitus. *Diabetes Care*. Vol. 32 (Supplement 1) S62-S67; DOI: 10.2337/dc09-S062
- [8] Hovorka R. (2015). Artificial Pancreas Project at Cambridge 2013. *Diabetic medicine : a journal of the British Diabetic Association*, 32(8), 987-992. DOI : 10.1111/dme.12766
- [9] Sudharsan, B., Peeples, M., & Shomali, M. (2015). Hypoglycemia prediction using machine learning models for patients with type 2 diabetes. *Journal of diabetes science and technology*, 9(1), 86-90. DOI : 10.1177/1932296814554260
- [10] Zhang, L., Wang, Y., Niu, M., Wang, C., & Wang, Z. (2020). Machine learning for characterizing risk of type 2 diabetes mellitus in a rural Chinese population: the Henan Rural Cohort Study. *Scientific reports*, 10(1), 4406. DOI : 10.1038/s41598-020-61123-x
- [11] Plis, K., Bunescu, R.C., Marling, C., Shubrook, J., & Schwartz, F. (2014). A Machine Learning Approach to Predicting Blood Glucose Levels for Diabetes Management. *AAAI Workshop: Modern Artificial Intelligence for Health Analytics*.
- [12] Pustozarov, E., Popova, P., Tkachuk, A., Bolotko, Y., Yuldashev, Z., & Grineva, E. (2018). Development and Evaluation of a Mobile Personalized Blood Glucose Prediction System for Patients With Gestational Diabetes Mellitus. *JMIR mHealth and uHealth*, 6(1), e6. DOI : 10.2196/mhealth.9236
- [13] Konstam M. A. (2012). Home monitoring should be the central element in an effective program of heart failure disease management. *Circulation*, 125(6), 820-827. DOI : 10.1161/CIRCULATIONAHA.111.031161
- [14] Fye W. B. (1994). A history of the origin, evolution, and impact of electrocardiography. *The American journal of cardiology*. 73(13). 937-949. DOI : 10.1016/0002-9149(94)90135-x
- [15] Gordon J. W. (1877). Certain Molar Movements of the Human Body produced by the Circulation of the Blood. *Journal of anatomy and physiology*, 11(Pt 3), 533-536.
- [16] Alvarado-Serrano, C., Luna-Lozano, P.S., & Pallás-Areny, R. (2016). An algorithm for beat-to-beat heart rate detection from the BCG based on the continuous spline wavelet transform. *Biomed. Signal Process. Control.*, 27, 96-102. DOI : 10.1016/j.bspc.2016.02.002.
- [17] Murata, (2020.09.10). *Contactless Bed Sensor, Inertial force Sensor*. Murata Manufacturing Co., Ltd. [http://www.murata.com/products/sensor/accel/sca10\\_h\\_11h](http://www.murata.com/products/sensor/accel/sca10_h_11h).
- [18] Amos, A. F., McCarty, D. J., & Zimmet, P. (1997). The rising global burden of diabetes and its complications: estimates and projections to the year 2010. *Diabetic medicine : a journal of the British Diabetic Association*, 14 Suppl 5, S1-S85.
- [19] Korean Diabetes Association. (2021.04.05) *2021 Diabetes Treatment Guidelines Guidelines*.

- <https://www.diabetes.or.kr/pro/publish/guide.php?mode=list>
- [20] Heinemann, L., & Boecker, D. (2011). Lancing: quo vadis?. *Journal of diabetes science and technology*, 5(4), 966-981.  
DOI : 10.1177/193229681100500420
- [21] Lyandres, O., Yuen, J. M., Shah, N. C., VanDuyne, R. P., Walsh, J. T., & Glucksberg, M. R. (2008). Progress toward an in vivo surface-enhanced Raman spectroscopy glucose sensor. *Diabetes technology & therapeutics*, 10(4), 257-265.  
DOI : 10.1089/dia.2007.0288
- [22] Wahr, J. A., Tremper, K. K., Samra, S., & Delpy, D. T. (1996). Near-infrared spectroscopy: theory and applications. *Journal of cardiothoracic and vascular anesthesia*, 10(3), 406-418.  
DOI : 10.1016/s1053-0770(96)80107-8
- [23] Siesler, Heinz & Ozaki, Yukihiro & Kawata, S. & Heise, Herbert. (2002). *Near-Infrared Spectroscopy: Principles, Instruments, Applications*. 16. 636-638.
- [24] Sbrignadello, Stefano & Tura, Andrea & Ravazzani, Paolo. (2013). Electroimpedance Spectroscopy for the Measurement of the Dielectric Properties of Sodium Chloride Solutions at Different Glucose Concentrations. *Journal of Spectroscopy*. 2013.  
DOI : 10.1155/2013/571372.
- [25] Murata Electronics. (2021.4.15). *Acceleration Sensor Modules SCA11H-A01-036 Data Sheet*.  
[https://www.murata.com/en-global/products/sensor/accel/overview/lineup/sca10h\\_11h](https://www.murata.com/en-global/products/sensor/accel/overview/lineup/sca10h_11h).
- [26] Ministry of Food and Drug Safety. (2019.09.23). *Blood glucose monitoring systems, self-testing*.  
[https://udiportal.mfds.go.kr/brd/view/P03\\_01?ntceSn=14](https://udiportal.mfds.go.kr/brd/view/P03_01?ntceSn=14)
- [27] Accu-chek Instant. (2019. 3. 21). *User's Manual; Blood Glucose Meter*. <https://www.accu-chekcac.com/en/download/file/fid/13361>
- [28] Murata Electronics. (2015.11.12). *Ballistocardiographic sensors provide contact-less approach to measuring patient vital signs*.  
<https://www.murata.com/en-eu/products/info/sensor/accel/2015/1112>
- [29] Sami Nurmi, (2016). *Nocturnal sleep quality and quantity analysis with ballistocardiography*. School of Electrical Engineering, Espoo, Finland, 2016.
- [30] Sang-Ki, Choi., Geo-Lyong, Lee., (2020). Heart rate monitoring and predictability of diabetes using ballistocardiogram(pilot study). *Journal of Digital Convergence*. Vol.18. No.8. 231-242.  
10.14400/JDC.2020.18.8.231
- [31] Clarke, W. L., Cox, D., Gonder-Frederick, L. A., Carter, W., & Pohl, S. L. (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
- [32] Benichou, T., Pereira, B., Mermillod, M., Tauveron, I., Pfabigan, D., Maqdasy, S., & Dutheil, F. (2018). Heart rate variability in type 2 diabetes mellitus: A systematic review and meta-analysis. *PloS one*, 13(4), e0195166.  
DOI : 10.1371/journal.pone.0195166
- [33] Minato, S., Takenouchi, A., Uchida, J., Tsuboi, A., Kurata, M., Fukuo, K., & Kazumi, T. (2017). Association of Whole Blood Viscosity With Metabolic Syndrome in Type 2 Diabetic Patients: Independent Association With Post-Breakfast Triglyceridemia. *Journal of clinical medicine research*, 9(4), 332-338.  
DOI : 10.14740/jocmr2885w
- [34] Ahn, C. W.. (2014). *Clinical study for diagnostic efficacy of diabetic angiopathy using hemorheological measurement system (RheoScan)*. MOHW. Health Technology R&D Project. Yonsei University Industry-Academic Innovation Team
- [35] Clarke W. L. (2005). The original Clarke Error Grid Analysis (EGA). *Diabetes technology & therapeutics*, 7(5), 776-779.  
DOI : 10.1089/dia.2005.7.776

최 상 기(Sang-Ki Choi)

[상학원]



- 2016년 2월 : 선문대학교 통합의학과 박사과정 수료
- 2016년 4월 ~ 현재 : 소프트웨어융합 연구소 연구소장
- 관심분야 : 웰니스, 융합의과학, IT Convergence
- E-Mail : dumoak@naver.com

박 철 구(Cheol-Gu Park)

[상학원]



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