

POST-TAVR ECG 기반의 PPI 예측 모델 연구[☆]

Research of PPI prediction model based on POST-TAVR ECG

송인서¹ 양세모¹ 이강윤^{1*}
InSeo Song SeMo Yang KangYoon Lee

요약

경피적 대동맥 판막 치환술(TAVR) 후에는 인공 심박동기 삽입술(PPI)을 비롯한 TAVR 이후 합병증에 대한 철저한 관리가 필요하며 그에 따라 정확한 예측 모델에 대한 필요성이 점점 증가하고 있다. 본 연구는 기존의 이미지 의존적 방법론에서 벗어나 ECG 정보를 중심으로 예측하는 XGBoost 기반의 최적의 PPI 예측 모델을 개발했다. 이 모델은 심전도상의 특정 신호들인 DeltaPR, DeltaQRS 등을 주요 지표로 삼아, 환자의 전도 장애 및 PPI와의 연관성을 파악하며, 기존의 이미지와 ECG 데이터를 결합한 모델과 ECG 기반의 모델 보다 뛰어난 AUC 0.91 성능을 달성하였다. 본 연구에서 제안하는 모델은 두 병원의 데이터를 기반으로 최적의 PPI 예측 모델을 구현 및 검증하였으며, 검증 결과 ECG 데이터의 특성이 PPI 예측에 큰 영향을 미치며 95.28%의 높은 유사도를 보였다. 이로써 본 연구의 예측 모델이 다양한 병원 데이터에도 효과적으로 적용될 수 있음을 확인하였다. 최적의 머신러닝 알고리즘을 사용하여 PPI와 각 특성 간의 상관관계를 명확히 했으며, 고비용의 의료 이미지에 의존하지 않고 ECG 데이터를 사용하여 높은 정확도로 PPI를 예측할 수 있음을 입증하였다. 이는 의료 결정 과정에서 인간 개입의 의존도를 줄이며, 신뢰할 수 있고 실용적인 PPI 예측 모델 개발로의 중요한 진전을 의미한다.

☞ 주제어 : 머신러닝, 경피적 대동맥 판막 치환술, 인공 심박동기 삽입술

ABSTRACT

After Transcatheter Aortic Valve Replacement (TAVR), comprehensive management of complications, including the need for Permanent Pacemaker Implantation (PPI), is crucial, increasing the demand for accurate prediction models. Departing from traditional image-based methods, this study developed an optimal PPI prediction model based on ECG data using the XGBoost algorithm. Focusing on ECG signals like DeltaPR and DeltaQRS as key indicators, the model effectively identifies the correlation between conduction disorders and PPI needs, achieving superior performance with an AUC of 0.91. Validated using data from two hospitals, it demonstrated a high similarity rate of 95.28% in predicting PPI from ECG characteristics. This confirms the model's effective applicability across diverse hospital data, establishing a significant advancement in the development of reliable and practical PPI prediction models with reduced dependence on human intervention and costly medical imaging.

☞ keyword : Machine Learning, Transcatheter Aortic Valve Replacement(TAVR), Permanent Pacemaker Implantation(PPI)

1. 서론

경피적 대동맥 판막 치환술(Transcatheter Aortic Valve Replacement, TAVR)은 대동맥 판막 협착증 환자에게 필요한 수술이다. TAVR 이후 다양한 합병증이 발생할 수 있는데, 그중 하나는 심장의 전도계에 대한 영향이다.

TAVR 과정에서 삽입되는 인공 판막은 심장의 전도계와 근접한 위치에 있는데, 주변에 압력을 가하는 경우 심장 박동수 감소나 전도장애와 같은 부정맥을 유발한다. 이러한 상태는 환자의 삶의 질을 크게 저하시킬 뿐만 아니라 생명을 위협할 수도 있다. 인공 심박동기 삽입술(Pacemaker Implantation, PPI)은 심장의 전기 자극을 조절하여 맥박 활동에 문제가 있을 때, 불규칙한 리듬을 복구하여 정상 범위의 맥박을 유지하기 위해 사용되는 중요한 의료 절차이다.[1]

본 연구는 ECG 데이터를 활용하여 PPI를 예측하는 새로운 접근법을 제시한다. 이는 환자의 TAVR 이후 잠재적 위험 요소를 조기에 식별하여 개인화된 치료 계획의 수립과 환자의 건강 상태를 개선하는 데 중요한 역할을 한다.[2][3][4]

¹ Dept. of Computer Engineering, Gachon University, Seongnam, 13120, Korea

* Corresponding author (keylee@gachon.ac.kr)

[Received 20 December 2023, Reviewed 28 December 2023(R2 29 February 2024), Accepted 07 March 2024]

[☆] 본 연구는 보건복지부의 재원으로 한국보건산업진흥원의 보건 의료기술연구개발사업(과제 : H122C1651)과 한국연구재단의 기초연구사업(grant number: NRF-2022R1F1A1069069) 지원에 의하여 이루어진 것임

ECG 정보를 기반으로 PPI를 예측하는 머신러닝 모델은 병의 증세가 드러나지 않은 환자들을 조기에 식별하여 질병 예방과 조기 치료에 있어 도움이 될 수 있지만, 실제 도입에는 한계가 남아 있다.[5] 지금까지의 연구에서는 주로 CT, 심초음파와 같은 의료 이미지와 ECG 데이터를 결합하여 PPI를 예측하는 방법이 일반적이었다.

하지만 이 방법은 때때로 의료 전문의의 개입을 필요로 하고, 낮은 예측 정확도를 지니는 문제가 있다.[5] 본 연구는 이러한 한계를 극복하고자 한다. 특히, ECG는 CT, 심초음파와 같은 의료 이미지보다 저렴하며, 일반적으로 광범위하게 사용되기에 ECG를 중점적으로 활용하여 PPI를 예측하는 모델이 의료 현장에서 접근성과 경제성 측면에서 유리하며, 더 많은 환자에게 보다 개선된 건강 관리와 질병 예방의 혜택을 제공할 가능성을 지니고 있다.[5]

본 연구에서는 Extreme Gradient Boosting을 기반으로 하여 ECG 데이터를 중심으로 PPI를 예측하는 최적의 모델을 개발했다. 이는 CT, 심초음파와 같은 의료 이미지 없이 높은 정확도의 예측이 가능함을 보여주며, 의료 전문가의 개입 없이 기존 모델들보다 더 우수한 성능을 제공한다.

PPI는 전도 장애와 밀접한 연관이 있으며, 전도 장애를 판단할 때 중요한 ECG 특성들이 존재한다.[6-11] 이를 바탕으로 모델이 PPI를 예측할 때 ECG 특성들과 PPI 사이의 상관관계 및 중요성을 올바르게 판단하고 활용하는지를 확인하고, 의료 이미지에 의존하지 않고도 높은 정확도로 예측이 가능한 새로운 방법을 제시한다.[5]

본 연구는 관련 연구 검토를 통해 PPI 예측에 관한 연구 동향과 기존 연구의 한계점을 분석하여 이를 극복하고자 한다. 연구에서 사용한 데이터와 전처리 과정에 대해 설명하며, XGBoost 알고리즘을 활용한 PPI 예측 모델의 개발 과정을 자세히 논한다. 또한, 모델의 성능 평가 및 검증과 더불어 특성 중요도 분석을 통해 도출된 주요 발견들을 바탕으로, 본 모델이 의료 분야에서 조기 진단 및 환자의 건강관리 과정의 개선에 기여하는 바를 논의한다.

2. 관련 연구

2.1 ECG 기반 심장질환 예측 모델 연구

ECG 데이터를 활용하여 다양한 종류의 심장 질환에 대해서 예측하는 딥러닝 모델을 개발하였다. 심초음파 데

이터를 사용하여 심장질환들을 라벨링 하였고, ECG 데이터를 사용하여 학습과 예측을 진행했다. 예측 정확도를 평가하여 ROC-AUC 값 0.91을 확인했으며 해당하는 심장질환을 높은 정확도로 예측할 수 있다. 해당 연구에서는 심초음파 데이터로는 진단되지 않은 심장질환을 가진 환자를 식별하는 데 ECG 데이터를 중점적으로 활용한다. 이러한 접근 방식은 환자에게 위험한 질환의 조기 발견과 치료에 중대한 영향을 미치는 실질적인 의료적 가치를 제공한다.[5] ECG 기반 예측 모델은 의료 이미지에서 식별할 수 없는 내용에 대해 예측할 수 있으며 의료 이미지를 배제한 것이 더 좋은 결과를 보여준다는 것을 증명한다.

2.2 PPI 예측 머신러닝 모델 연구

머신러닝 알고리즘을 활용한 TAVR 이후 PPI의 필요성을 예측하는 모델 개발에 관한 연구는 지속해서 전개되고 있다. 기존 연구들은 의료 이미지와 ECG 데이터를 통합하여 활용하는 방식[11-15]에 중점을 두었으나 ECG를 중심으로 분석하는 연구도 진행되고 있다.[16-20]

2.2.1 심초음파와 ECG를 기반으로 한 GBM 모델 개발

1,200명의 TAVR을 받은 대동맥 협착증 환자들을 대상으로 진행되었다. 심초음파와 ECG 정보를 결합한 데이터를 기반으로 TAVR 이후 PPI를 예측하기 위해 Gradient Boosting Machine(GBM) 알고리즘을 사용했으며 표 1에서 처럼 ROC-AUC 값 0.72를 확인했다. 이는 심장 질환의 진단 및 치료과정에서 의료 이미지와 ECG의 통합적 활용을 강조하는 사례이며 포괄적인 환자 분석을 수행할 방법을 제시한다.[12]

2.2.2 PPI를 예측하는 RF 모델 개발 및 ECG 데이터의 유용성 조사

557명의 TAVR을 받은 환자들을 대상으로 진행되었다. PPI를 예측하기 위해 Random Forest(RF), Logistic Regression(LR) 등의 알고리즘을 사용했으며 가장 뛰어난 성능은 ROC-AUC 값 0.81의 RF 모델이다. TAVR 이후 ECG 데이터를 포함한 RF 모델은 TAVR 이후 ECG 데이터를 포함하지 않은 RF 모델(AUC 0.72)보다 PPI를 더 정확하게 예측했다. 또한, RF 모델은 표 1에서 처럼 LR 모델(AUC 0.72)보다 PPI를 예측하는 데 있어 더 나은 성능을 보였다.[16]

2.2.3 TAVR 이전 ECG를 사용하여 TAVR 이후 PPI를 예측하는 모델 개발

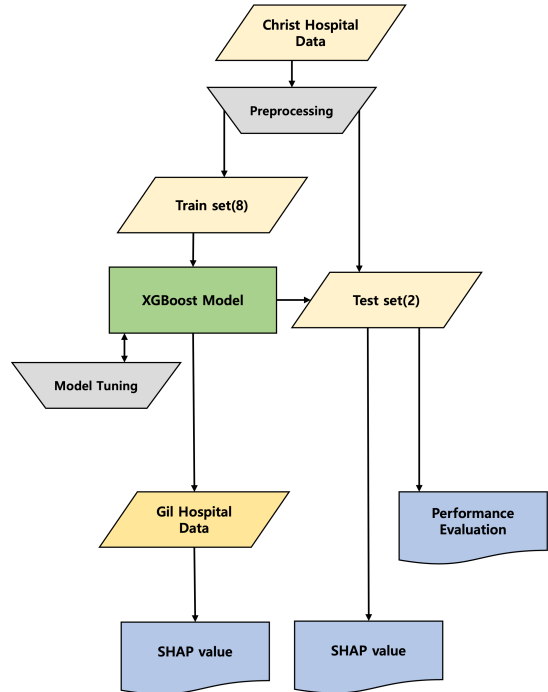
TAVR을 받은 1,032명의 환자를 대상으로 한 후향적 연구이며 ECG 데이터를 기반으로 진행했다. Waikato Environment for Knowledge Analysis(WEKA)를 사용하여 TAVR 이후 PPI를 예측하는 최상의 머신러닝 알고리즘 5개를 확인했으며 그중 가장 뛰어난 성능은 표 1에서처럼 ROC-AUC 값 0.76이다. 이는 ECG 데이터가 TAVR 이후 PPI를 결정하는 중요한 요인으로 사용되며 머신러닝 모델이 PPI를 예측하는 데 유용할 수 있음을 보여준다.[19]

(표 1) 기존 연구들의 모델 성능(ROC-AUC)
(Table 1) Model performance of existing research(ROC-AUC)

모델	2.2.1	2.2.2	2.2.3
RF	-	0.81	-
LR	-	0.69	-
DT	-	0.68	-
SVM	-	0.75	-
GBM	0.72	0.76	-
NN	-	0.66	-
WEKA	-	-	0.76

3. 연구 방법

본 연구의 진행 단계는 그림 1과 같다. Christ 병원 데이터의 결측치를 해결하기 위해 전처리 과정을 거친 데이터를 8:2의 비율로 학습 데이터와 테스트 데이터를 분리하였다. 학습 과정에서 모델의 성능을 높이기 위해 4가지 항목을 정의하여 학습 속도와 정확도, 모델의 결정 트리 복잡성, 특성 활용 정도, 데이터 셋에 대한 과적합을 중점적으로 모델의 하이퍼 파라미터 튜닝을 진행했다. 기존 연구에서의 모델들과 개발한 모델의 성능 평가를 했으며 각 특성이 예측에 미치는 영향력을 Christ 병원과 길병원 데이터 각각에 대해 분석하여 비교를 진행했다. 본 연구는 가천대학교 길병원 기관생명윤리심의위원회(윤리 승인 코드: GAIRB 2022-345)의 승인을 받아 동의서 제출이 면제되었으며 연구 과정에서의 수집된 데이터 관리 및 활용에 있어 윤리적 기준을 준수하여 진행하였다.



(그림 1) 연구 진행단계 흐름도
(Figure 1) Research progress flow chart

3.1 데이터

TAVR 이후 PPI 여부를 식별 가능한 The Christ hospital의 2011년 5월부터 2019년 5월까지 553명의 데이터를 사용하였다.

표 2의 내용처럼 Clinical 특성(나이, 성별, 신체 표면적(BSA), 체질량지수(BMI), 고혈압 병력(HTN), 관상동맥질환(CAD), 당뇨병(DM), 기준 수축기 혈압(SystolicBP), 기준 이완기 혈압(DiastolicBP)), 기준 심장 약물 특성(ACE 억제제(ACEi_ARB), 베타차단제(Beta_Blocker), 알도스테론 길항제(Aldosteroneantagonist), 칼슘 채널 차단제(CCB), 항혈소판제, 이뇨제(Diuretics)), 좌심실 박출률(LVEF), 좌심실 유출관 치수(LVOT)가 있으며 특성 중 BSA, BMI, SystolicBP, DiastolicBP, LVEF, LVOT 항목의 결측치를 확인했다. 이 항목들은 모델 학습 및 예측, 평가에서 Baseline 특성으로 사용되었다. 추가로 표 3은 ECG 특성이며 DeltaPR과 DeltaQRS는 TAVR 이후 PR 및 QRS 간격 값의 차이로 정의되었다.

(표 2) 크리스 병원 데이터 정보(기준선)
(Table 2) Christ Hospital Data(Baseline)

	n = 449	n = 104
Age	78.83 ±8.73	80.52 ±8.00
Sex	1(225) / 0(224)	1(37) / 0(67)
BSA	1.94 ±0.26	2.03 ±0.27
BMI	28.89 ±6.41	29.87 ±6.31
HTN	1(387) / 0(62)	1(98) / 0(6)
CAD	1(249) / 0(200)	1(53) / 0(51)
DM	1(163) / 0(286)	1(36) / 0(68)
SystolicBP	133.00 ±17.81	132.55 ±19.84
DiastlicBP	70.75 ±11.24	69.76 ±9.72
ACEi_ARB	1(190) / 0(259)	1(36) / 0(68)
Beta_Blocker	1(263) / 0(186)	1(63) / 0(41)
Aldosterone antagonist	1(59) / 0(390)	1(9) / 0(95)
CCB	1(111) / 0(338)	1(24) / 0(80)
AntiPlatele totherthanASA	1(179) / 0(270)	1(9) / 0(95)
ASA	1(300) / 0(149)	1(63) / 0(41)
AntiPlatelet Therapy	1(370) / 0(79)	1(84) / 0(20)
Diuretics	1(269) / 0(180)	1(70) / 0(34)
LVEF	53.24 ±11.42	54.29 ±10.41
LVOT	20.31 ±1.54	20.44 ±1.58
ValveCode	1(215) / 2(37) / 3(197)	1(23) / 2(27) / 3(54)
ValveSize	26.92 ±3.37	28.09 ±3.59

(표 3) 크리스 병원 데이터 정보(심전도)
(Table 3) Christ Hospital Data(ECG)

	n = 449	n = 104
Baseline Rythm	1(78) / 0(371)	1(28) / 0(76)
PR	182.61 ±28.50	191.37 ±33.09
QRS	103.47 ±21.22	116.73 ±24.59
QRSmore than120	1(80) / 0(369)	1(50) / 0(54)
Firstdegree AVblock	1(95) / 0(269)	1(31) / 0(44)
BaselineRBBB	1(37) / 0(412)	1(41) / 0(63)
DeltaPR	13.36 ±18.73	27.75 ±24.85
DeltaQRS	17.02 ±24.80	28.37 ±26.13
New_Onset_LBBB	1(110) / 0(339)	1(32) / 0(72)

3.2 데이터 전처리

데이터셋에서 누락된 값을 처리하기 위해 SimpleImputer 추정기를 활용하여 결측치를 각 특성의 평균값으로 대체하였다. 이 방식은 원본 데이터의 분포를 크게 왜곡시키지 않으면서 전체 집합의 중심을 잘 나타내는 평균값을 사용함으로써 데이터셋의 전반적인 경향성을 보존한다. 평균값의 사용은 특히 데이터 포인트가 많은 상황에서 효과적이며, 추가적인 변동성 없이 일관성 있는 데이터 처리를 보장한다. 이는 중앙값, 최빈값을 사용하거나 기계 학습을 활용하는 다른 접근법들이 데이터에 도입할 수 있는 변동성과는 대비되는 장점이다. 또한, 평균값은 모든 데이터 포인트를 고려함으로써 이상치의 영향을 완화하는 데 효과적이다. 이 방법론을 바탕으로, 데이터셋은 8:2의 비율로 학습 데이터와 테스트 데이터로 분리하여 예측 모델의 학습 및 평가를 진행했다.

3.3 PPI 예측 모델

Extreme Gradient Boosting (XGBoost) 알고리즘은 여러 머신러닝 알고리즘 중에서도 고도의 최적화와 병렬 처리로 빠른 학습 속도를 제공하며 과적합 방지를 위한 규제 기능 및 교차검증, 일반화 능력을 향상시키는 트리 가지 치기와 같은 기능을 통해 뛰어난 성능과 효율성을 제공한다. 또한 성능을 높이는 데 중요한 역할을 하는 손실함수에 대해 정의 가능한 다양한 함수를 지원하기에 높은 예측 정확도를 달성하려는 본 연구의 목적에 맞는 최적의 학습 모델로 이를 사용하여 PPI 예측 모델을 개발하였다.

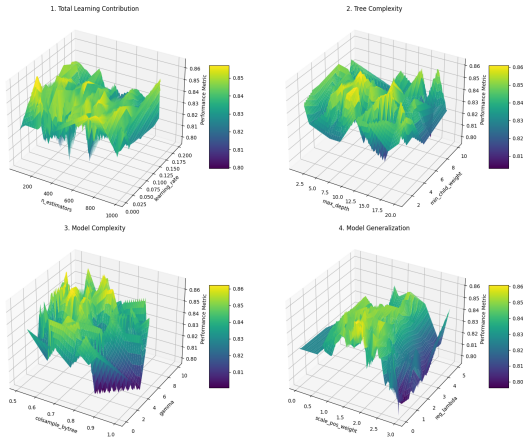
XGBoost는 Gradient Tree Boosting 알고리즘의 원리를 확장하여 여러 개의 약한 학습 트리를 조합해 우수한 결정 트리를 만드는 머신러닝 기법이다.

$$OBJ(\theta) = L(\theta) + \Omega(\theta)$$

$L(\theta)$ 는 훈련 과정에서 손실 함수를 의미하며 모델의 진행 상황을 평가하고, $\Omega(\theta)$ 는 규제를 의미하며 모델의 복잡성을 제어하며 중복이나 격차를 줄이는 데 사용한다. XGBoost의 핵심은 목적 함수 $OBJ(\theta)$ 의 최소화, 오류율을 줄이는 것을 목표로 하며 반복적으로 오류를 최소화하기 위해 가중치 값을 업데이트할 때 경사 하강법을 사용한다.[21]

3.4 예측 모델 최적화를 위한 튜닝

최적의 PPI 예측 모델을 만들기 위해 부스팅 알고리즘의 특성에 기반하여 그림 2와 같이 Total Learning Contribution, Tree Complexity, Model Complexity, Model Generalization의 4가지 항목을 정의하고 이를 최적화했다.



(그림 2) 하이퍼파라미터 튜닝 과정

(Figure 2) Hyperparameter tuning process

$$Total\ Learning\ Contribution = n_estimators \times learning_rate$$

Total Learning Contribution은 모델이 학습하는 동안 전체적으로 얻는 지식의 양을 의미한다. learning_rate를 낮추면 각 부스팅 단계에서의 조정이 더 세밀해져 목표 값에 대해 작은 변화만을 모델에 반영하기 때문에 동일한 학습 수준에 도달하기 위해 더 많은 n_estimators가 필요하다.

$$Tree\ Complexity = \frac{max_depth}{min_child_weight}$$

Tree Complexity는 트리의 복잡성을 의미한다. max_depth가 증가하면 트리는 더 복잡해지고, min_child_weight가 증가하면 트리의 분기가 줄어 과적합을 방지하는 데 도움이 된다.

$$Model\ Complexity = \frac{colsample_bytree}{gamma}$$

Model Complexity는 모델의 전체적인 복잡성을 의미한다. colsample_bytree가 증가하면 모델은 더 많은 피처를 사용하여 복잡해지는 반면, gamma가 증가하면 트리가 불필요하게 깊어지는 것을 방지하여 모델을 간단하게 유지한다.

$$Model\ Generalization = \frac{scale_pos_weight}{reg_lambda}$$

Model Generalization은 모델의 일반화 능력을 의미한다. scale_pos_weight는 양성 클래스에 대한 가중치를 증가시켜 불균형 데이터에서의 성능을 개선하며 reg_lambda는 L2 정규화를 통해 모델의 복잡성을 줄이고 과적합을 방지한다.

본 연구에서는 XGBoost를 기반으로 앞서 정의한 4가지 항목별 범위를 지정하여 각 하이퍼파라미터가 가질 수 있는 가능한 값의 범위인 탐색 공간을 설정했으며, 이전의 평가 결과를 바탕으로 새로운 후보 값을 제안하는 Bayesian Optimization 기법을 사용하여 정확도를 기준으로 한 실험적 탐색을 통해 범위를 조정하며 최종 하이퍼파라미터 값을 정의했다. 해당 값으로 모델 최종 학습을 진행했으며 XGBoost가 과적합 방지를 위해 지원하는 기능 eval_set을 적용하여 각 부스팅 라운드 후 검증하는 과정을 추가했다. 이 과정에서 성능 모니터링을 통해 라운드 별 모델 개선 여부를 판단하여 PPI를 예측하는 최적의 모델을 완성했다.

3.5 성능 평가 방법

ECG 기반의 PPI 예측 모델의 성능을 평가하기 위해 ROC-AUC와 SHAP values를 사용한다. ROC-AUC 값은 분류 모델의 성능을 평가할 때 사용되며 기존 연구들에서 개발한 예측 모델의 성능을 평가할 때 해당 지표를 사용하였다. 또한 모델의 예측 과정에서 각 특성의 영향력과 기여도를 확인하고 분석하기 위해 SHAP values를 사용한다.

3.5.1 ROC-AUC

본 연구는 ROC-AUC(Receiver Operating Characteristic - Area Under Curve)를 사용하여 모델의 성능을 평가한다.

$$TPR = \frac{TP}{TP + FN}$$

True Positive Rate(TPR, Sensitivity): 모델이 양성 클래스를 정확히 예측하는 능력을 나타낸다.

$$FPR = \frac{FP}{FP + TN}$$

False Positive Rate(FPR, 1 - Specificity): 모델이 음성 클래스를 양성 클래스로 잘못 분류하는 비율을 나타낸다.

ROC Curve는 다양한 임계값에서 TPR과 FPR을 그래프로 나타내며 AUC는 ROC 곡선 아래 영역의 면적으로, 이 값이 0.5일 때는 무작위 추측 수준의 성능을, 1에 가까울수록 모델의 성능이 뛰어난 것을 의미한다.


3.5.2 SHAP values

SHAP values(Shapley Additive exPlanations)는 각 특성이 모델이 예측하는데 얼마나 영향을 미쳤는지를 수치적으로 나타낸다. SHAP value는 모든 특성이 예측에 공평하게 기여한다는 가정하에 계산되기에 각 특성의 중요도를 정확하고 공정하게 평가할 수 있으며 모델의 결정 과정을 더 깊이 이해할 수 있다.

4. 연구 결과

4.1 예측 모델의 성능 평가

본 연구에서 개발한 예측 모델은 Christ Hospital 데이



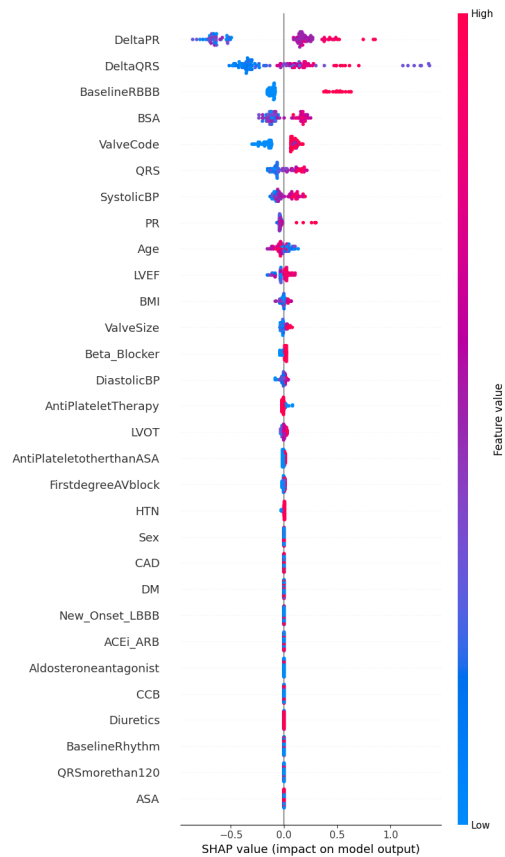
(그림 3) 개발한 XGBoost 모델의 성능 비교

(Figure 3) Performance comparison of the developed XGBoost model


터의 환자 553명 중 104명을 평가 데이터 셋으로 사용하였으며, 모델은 ROC-AUC 값 0.91로 높은 예측 성능을 보였다. 기존 연구에서 CT, 심초음파와 같은 의료 이미지와 ECG 정보를 결합한 데이터를 사용한 GBM 모델은 ROC-AUC 값 0.72[5], ECG 데이터를 사용한 RF 모델은 ROC-AUC 값 0.81[9]로 본 연구에서 개발한 예측 모델의 성능이 기존 모델들보다 뛰어난 것을 그림 3과 같이 확인할 수 있다.

4.2 Shap value를 활용한 특성 중요도 분석

예측 모델의 특성 중요도 분석은 두 가지 주요 데이터 셋에서 수행되었으며 그림 4, 그림 5는 각각의 데이터에 대한 Shap value를 시각화한 지표이다. Christ Hospital Test



(그림 4) 크리스 병원 데이터 SHAP (Figure 4) Christ Hospital Data SHAP



(그림 5) 길 병원 데이터 SHAP
(Figure 5) Gil Hospital Data SHAP

Data Set과 Gil Hospital Data를 사용한 분석에서 모두 DeltaPR, DeltaQRS에 대한 ECG 특성이 모델 예측에 있어 가장 큰 영향을 미치는 것으로 나타났으며 각각 25.65%, 20.69%의 영향력을 가지고 있다. 이는 전도 장애와 밀접한 연관성이 있는 ECG 특성이며, PPI 예측에 있어서 핵심적인 역할을 하는 특성들이다.[6-11] 모델은 이 특성들을 예측에 중요한 역할로 사용하며 이는 예측 결과가 신뢰성을 가진다는 것을 의미한다.[8] 또한 XGBoost 알고리즘을 기반으로 한 예측 모델이 주어진 데이터 셋의 ECG 특성을 활용하여 PPI를 높은 정확도로 예측할 수 있으며 학습 과정에서 최적의 하이퍼파라미터를 적용하면 모델은 예측할 때 특성과 중요한 패턴과 상관관계를 의료 전문가의 개입 없이 식별할 수 있음을 보여준다.[22]

Christ Hospital Test Data Set과 Gil Hospital Data를 예측

할 때 특성 중요도 95.28%의 유사성을 확인할 수 있으며 이를 통해 본 연구의 모델은 TAVR 이후 PPI 예측이 필요한 의료 문제 해결을 위한 핵심 도구로서의 가치를 지니고 있음을 확인하였다.

5. 결 론

TAVR 이후 PPI를 정확히 예측하기 위해 XGBoost 기반의 ECG 데이터를 중점적으로 활용하는 예측 모델을 개발하고 검증했다. 완성된 모델은 AUC 0.91의 높은 예측 정확도를 가지며 기존의 의료 이미지 의존적 방법론과 ECG 기반 예측 모델들에 비해 뛰어난 성능을 보인다. 모델은 DeltaPR, DeltaQRS에 대한 ECG 특성과 PPI의 상관관계를 식별하여 이를 예측에 중요한 특성으로 사용함으로써 신뢰성 있는 예측 결과임을 보여준다.

본 연구에서 개발한 모델은 의료 이미지에 의존하지 않고 높은 정확도로 PPI를 예측할 수 있음을 입증하며, TAVR 이후 환자의 PPI를 조기에 식별함으로써, 잠재적인 합병증을 예방하는 데 기여할 것이다. 또한, 의료 전문의의 개입 및 의존도를 줄이는 동시에 신뢰할 수 있고 적용 가능한 실용적인 PPI 예측 모델로의 중요한 발전을 의미하며, 의료 서비스의 질을 높이는 데 중요한 역할을 할 것이다.

다만, 본 연구는 두 병원의 데이터를 기반으로 하여 모델을 검증하여 일관된 결과를 확인하였으나 인종, 지역, 질병상태 등 다양한 배경을 가진 환자 데이터가 포함되지 않아 모델의 일반화에는 한계가 있다. 향후 연구에서는 이러한 데이터를 통합하여 모델의 일반화 수준을 향상시켜야 하며 ECG 데이터를 활용하여 PPI뿐만 아니라 이외의 복합적 질병을 예측할 수 있는지 확인하는 것도 중요하다.

참고문헌(Reference)

- [1] Vincent Auffret, Rishi Puri, Marina Urena, Chekrallah Chamandi, Tania Rodriguez-Gabella, François Philippon and Josep Rodés-Cabau, "Conduction Disturbances After Transcatheter Aortic Valve Replacement," *Circulation*, Vol. 30, Issue 4, pp. 179-187, 2017.
<https://doi.org/10.1161/CIRCULATIONAHA.117.028352>
- [2] Yasser Sammour, Amar Krishnaswamy, Arnav Kumar, Rishi Puri, Khaldoun G. Tarakji, Najdat Bazarbashi, Serge Harb, Brian Griffin, Lars Svensson, Oussam

- Wazni, Samir R. Kapadia, "Incidence, Predictors, and Implications of Permanent Pacemaker Requirement After Transcatheter Aortic Valve Replacement," *JACC: Cardiovascular Interventions*, Vol. 14, Issue 2, pp.115-134, 2021.
<https://doi.org/10.1016/j.jcin.2020.09.063>
- [3] Lei Han, Yiziting Zhu, Yuwen Chen, Guoqiong Huang, Bin Yi, "LightGBM and XGBoost Learning Method for Postoperative Critical Illness Key Indicators Analysis," *KSII Transactions on Internet and Information Systems*, Vol. 17, No. 8, 2023.
<https://eds.p.ebscohost.com/abstract?site=eds&scope=site&jml=19767277&AN=171790242&h=YKSFTPRyTorcU4mlhNTAoi3yb7f%2b6PtOjweMrxWWg8j5Yd4MszHh%2fQ5ihtiiPf81YiRvJUW4oBiPcVOSYw%2bEw%3d%3d&crl=c&resultLocal=ErrCriNoResults&resultNs=Ehost&crlhashurl=login.aspx%3fdirect%3dtrue%26profile%3dehost%26scope%3dsite%26authype%3dcrawler%26jml%3d19767277%26AN%3d171790242>
- [4] Minje Seok, Wooseong Kim, Jiyoun Kim, "Machine Learning for Sarcopenia Prediction in the Elderly Using Socioeconomic, Infrastructure, and Quality-of-Life Data", *Healthcare*, Vol. 11, Issue 21, pp. 2881, 2023.
<https://doi.org/10.3390/healthcare11212881>
- [5] Alvaro E. Ulloa-Cerna, Linyuan Jing, John M. Pfeifer, Sushravya Raghunath, Jeffrey A. Ruhl, Daniel B. Rocha, Joseph B. Leader, Noah Zimmerman, Greg Lee, Steven R. Steinhubl, Christopher W. Good, Christopher M. Haggerty, Brandon K. Fornwalt and Ruijun Chen, "rECHOmmend: An ECG-Based Machine Learning Approach for Identifying Patients at Increased Risk of Undiagnosed Structural Heart Disease Detectable by Echocardiography," *Circulation*, Vol. 146, No. 1, pp.36-47, 2022.
<https://doi.org/10.1161/CIRCULATIONAHA.121.057869>
- [6] Mathew B. Morton, Joseph B. Morton, Harry G. Mond, "Aberrant Ventricular Conduction: Revisiting an Old Concept," *Heart Lung and Circulation*, Vol32, Issue5, pp.555-566, 2023.
<https://doi.org/10.1016/j.hlc.2023.03.001>
- [7] Raffaele De Lucia, Cristina Giannini, Matteo Parollo, Valentina Barletta, Giulia Costa, Mario Giannotti Santoro, Chiara Primerano, Marco Angelillis, Marco De Carlo, Giulio Zucchelli, Maria Grazia Bongiorno, Anna Sonia Petronio, "Non-continuous mobile electrocardiogram monitoring for post-transcatheter aortic valve replacement delayed conduction disorders put to the test," *EP Europace*, Vol. 25, Issue 3, pp. 1116-1125, 2023.
<https://doi.org/10.1093/europace/euac285>
- [8] Charles F. Kircher, Nachiket Madhav Apte, Sagar Ranka, Rigoberto Ramirez, and Rhea C. Pimentel, "PRE AND POST TAVR PR AND QRS PARAMETERS HELP PREDICT NEED FOR A PERMANENT PACEMAKER FOLLOWING HOSPITAL DISCHARGE," *Journal of the american college of cardiology*, Vol. 79, Issue 9, pp.756, 2022.
[https://www.jacc.org/doi/abs/10.1016/S0735-1097\(22\)01747-8](https://www.jacc.org/doi/abs/10.1016/S0735-1097(22)01747-8)
- [9] Guillem Muntané-Carol, David del Val, Lucía Junquera, Laurent Faroux, Robert Delarochellière, Jean-Michel Paradis, Siamak Mohammadi, Dimitri Kalavrouziotis, Eric Dumont, François Philippon, Josep Rodés-Cabau, "Timing and evolution of advanced conduction disturbances in patients with right bundle branch block undergoing transcatheter aortic valve replacement," *EP Europace*, Vol. 22, Issue 10, pp. 1537-1546, 2020.
<https://doi.org/10.1093/europace/euaa149>
- [10] Roope Lahti, Jani Rankinen, Markku Eskola, Kjell Nikus, Jussi Hernesniemi, "Intraventricular conduction delays as a predictor of mortality in acute coronary syndromes," *European Heart Journal Acute Cardiovascular Care*, Vol. 12, Issue 7, pp. 430-436, 2023.
<https://doi.org/10.1093/ehjacc/zuad031>
- [11] Francesco Bruno, Fabrizio D'Ascenzo, Matteo Pio Vaira, Edoardo Elia, Pierluigi Omedè, Susheel Kodali, Marco Barbanti, Josep Rodès-Cabau, Oliver Husser, Samuel Sossalla, Nicolas M Van Mieghem, Jeroen Bax, David Hildick-Smith, Antonio Munoz-Garcia, Francesco Pollari, Theodor Fischlein,

- Carlo Budano, Antonio Montefusco, Guglielmo Gallone, Ovidio De Filippo, Mauro Rinaldi, Michele la Torre, Stefano Salizzoni, Francesco Atzeni, Marco Pocar, Federico Conrotto, Gaetano Maria De Ferrari, "Predictors of pacemaker implantation after transcatheter aortic valve implantation according to kind of prosthesis and risk profile: a systematic review and contemporary meta-analysis," *EHI-QCCO*, Vol. 7, Issue 2, pp. 143-153, 2021. <https://doi.org/10.1093/ehjqcc/qcaa089>
- [12] Pradyumna Agasthi, Hasan Ashraf, Sai Harika Pujari, Marlene Girardo, Andrew Tseng, Farouk Mookadam, Nithin Venepally, Matthew R Buras, Bishoy Abraham, Banveet K Khetarpal, Mohamed Allam, Siva K Mulpuru MD, Mackram F Eleid, Kevin L Greason, Nirat Beohar, John Sweeney, David Fortuin, David R Jr Holmes, Reza Arsanjani Agasthi P, Ashraf H, Pujari SH, Girardo M, Tseng A, Mookadam F, Venepally N, Buras MR, Abraham B, Khetarpal BK, Allam M, MD SKM, Eleid MF, Greason KL, Beohar N, Sweeney J, Fortuin D, Holmes DRJ, Arsanjani R, "Prediction of permanent pacemaker implantation after transcatheter aortic valve replacement: The role of machine learning," *World j Cardiol*, 15(3), pp. 95-105, 2023. <https://doi.org/10.4330/wjc.v15.i3.95>
- [13] Francisco Gama, Pedro de Araújo Gonçalves, João Abecasis, António Miguel Ferreira, Pedro Freitas, Mariana Gonçalves, Salomé Carvalho, Afonso Félix Oliveira, Henrique Mesquita Gabriel, João Brito, Luís Raposo, Pedro Adragão, Manuel de Sousa Almeida & Rui Campante Teles, "Predictors of pacemaker implantation after TAVI in a registry including self, balloon and mechanical expandable valves," *The International Journal of Cardiovascular Imaging*, Vol. 38, Issue 1, pp. 225-235, 2022. <https://doi.org/10.1007/s10554-021-02365-2>
- [14] Anan A. Abu Rmilah, Hossam Al-Zu'bi, Ikram-Ul Haq, Asil H. Yagmour, Suhaib A. Jaber, Adham K. Alkurashi, Ibraheem Qaisi, Gurukripa N. Kowlgi, Yong-Mei Cha, Siva Mulpuru, Christopher V. DeSimone, Abhishek J. Deshmukh, "Predicting permanent pacemaker implantation following transcatheter aortic valve replacement: A contemporary meta-analysis of 981,168 patients," *Heart Rhythm O2*, Vol. 3, Issue 4, pp. 385-392, 2022. <https://doi.org/10.1016/j.hroo.2022.05.001>
- [15] Amitabh C. Pandey, Arjun Nichani, Megan Pelter, Daniel Ng, Ashley Jaravata, Zabrina Duncan, Siddharth Suresh, Sandeep Mehta, Curtiss Stinis, Sanjeev Bhavnani, and Paul Teirstein, "MACHINE LEARNING FOR PREDICTION OF PACEMAKER AFTER TAVR IN PATIENTS WITH LOW STROKE VOLUME INDEX," *Journal of the American College of Cardiology*, Vol. 77, Issue 18, 2021. <https://www.jacc.org/doi/10.1016/S0735-1097%2821%2902541-9>
- [16] Yiming Qi, Xiaolei Lin, Wenzhi Pan, Xiaochun Zhang, Yuefan Ding, Shasha Chen, Lei Zhang, Daxin Zhou & Junbo Ge, "A prediction model for permanent pacemaker implantation after transcatheter aortic valve replacement," *European Journal of Medical Research*, Vol. 2, Issue 4, pp. 328-335, 2023. <https://doi.org/10.1186/s40001-023-01237-w>
- [17] Vien T. Truong, Daniel Beyerbach, Wojciech Mazur, Matthew Wigle, Emma Bateman, Akhil Pallerla, Tam N.M. Ngo, Satya Shreenivas, Justin T. Tretter, Cassidy Palmer, Dean J. Kereiakes, Eugene S. Chung, "Machine learning method for predicting pacemaker implantation following transcatheter aortic valve replacement," *Pace-Pacing and Clinical Electrophysiology*, Vol. 44, Issue 2, pp. 334-340, 2021. <https://doi.org/10.1111/pace.14163>
- [18] Takahiro Tsushima, Sadeer Al-Kindi, Fahd Nadeem, Guilherme F. Attizzani, Yakov Elgudin, Alan Markowitz, Marco A. Costa, Daniel I. Simon, Mauricio S. Arruda, Judith A. Mackall and Sergio G. Thal, "Machine Learning Algorithms for Prediction of Permanent Pacemaker Implantation After Transcatheter Aortic Valve Replacement," *Circulation: Arrhythmia and Electrophysiology*, Vol. 14, Issue 3, pp. 370-372, 2021. <https://doi.org/10.1161/circep.120.008941>
- [19] Jamal Hajjari, Takahiro Tsushima, Scott Janus,

- Heather Wheat, Cristian R Baeza, Sergio Thal, Guilherme Attizzani and Sadeer Al-Kindi, "Prediction of Post-TAVR Pacemaker Implantation Using Machine Learning on Pre-TAVR ECG," *Circulation*, Vol. 144, A9562, 2021.
https://doi.org/10.1161/circ.144.suppl_1.9562
- [20] George B. Black, Joshua H. Kim, Sophie Vitter, Rand Ibrahim, John C. Lisko, Emily Perdoncin, Nikoloz Shekiladze, Patrick T. Gleason, Kendra J. Grubb, Adam B. Greenbaum, Chandan M.Devireddy, Robert A. Guyton, Bradley Leshnowar, Faisal M. Merchant, Mikhael El-Chami, Stacy B. Westerman, Anand D. Shah, Angel R. Leon, Michael S. Lloyd, Vasilis C. Babaliaros, Soroosh Kiani , "Prospective validation of a risk score to predict pacemaker implantation after transcatheter aortic valve replacement," *Journal of Cardiovascular Electrophysiology*, Vol. 34, Issue 11, pp. 2225-2232, 2023.
<https://doi.org/10.1111/jce.16061>
- [21] Wei Liu, Zhangxin Chen, Yuan Hu, "XGBoost algorithm-based prediction of safety assessment for pipelines," *International Journal of Pressure Vessels and Piping*, Vol. 197, 2022.
<https://doi.org/10.1016/j.ijpvp.2022.104655>
- [22] Seo Hyun Oh, Min Kang, Youngho Lee, "Protected Health Information Recognition by Fine-Tuning a Pre-training Transformer Model," *Healthcare Informatics Research*, Vol. 28, No. 1, pp. 16-24, 2022.
<https://doi.org/10.4258/hir.2022.28.1.16>

● 저 자 소 개 ●




송 인 서 (InSeo Song)

2020년~현재: 가천대학교 컴퓨터공학과 (학사과정)
 관심분야 : 인공지능, IoT, 빅데이터 분석, 디지털 트윈
 E-mail : z8086486@gachon.ac.kr



양 세 모 (SeMo Yang)

2022년 가천대학교 컴퓨터공학과 (공학사)
 2024년 가천대학교 컴퓨터공학과 (공학석사)
 관심분야 : 인공지능, IoT, 빅데이터 분석, 디지털 트윈
 E-mail : tpah20@gachon.ac.kr



이 강 윤 (KangYoon Lee)

1986년 연세대학교 전자공학과 (공학사)
 1996년 연세대학교 전자계산학과 (공학석사)
 2010년 숭실대학교 IT정책경영 (공학박사)
 2016년~현재: 가천대학교 컴퓨터공학과 교수
 관심분야 : 인공지능, IoT, 빅데이터 활용, 솔루션, 디지털 트윈
 E-mail : keylee@gachon.ac.kr