

투석혈관 수술시기 예측을 위한 인공지능 알고리즘 개발*

김도형** · 김현숙*** · 이선표**** · 오인종***** · 박승범*****

Developing an Artificial Intelligence Algorithm to Predict the Timing of Dialysis Vascular Surgery

Kim Dohyoung · Kim Hyunsuk · Lee Sunpyo · Oh Injong · Park Seungbum

〈Abstract〉

In South Korea, chronic kidney disease(CKD) impacts around 4.6 million adults, leading to a high reliance on hemodialysis. For effective dialysis, vascular access is crucial, with decisions about vascular surgeries often made during dialysis sessions. Anticipating these needs could improve dialysis quality and patient comfort. This study investigates the use of Artificial Intelligence(AI) to predict the timing of surgeries for dialysis vessels, an area not extensively researched. We've developed an AI algorithm using predictive maintenance methods, transitioning from machine learning to a more advanced deep learning approach with Long Short-Term Memory(LSTM) models. The algorithm processes variables such as venous pressure, blood flow, and patient age, demonstrating high effectiveness with metrics exceeding 0.91. By shortening the data collection intervals, a more refined model can be obtained. Implementing this AI in clinical practice could notably enhance patient experience and the quality of medical services in dialysis, marking a significant advancement in the treatment of CKD.

Key Words : Vascular Access, AVF, Artificial Intelligence, Deep Learning, LSTM

I. 서론

문명과 의학 기술의 발전은 인간의 평균 수명을 증

가시켰으나, 이로 인한 노화와 노년인구의 증가는 당뇨와 고혈압 환자의 증가를 초래하였고[1], 나아가 만성콩팥병(chronic kidney disease, CKD)의 증가로 혈액 투석 환자는 지속적으로 증가하는 추세이다[2]. 국제 신장 학회(International Society of Nephrology)에서 공개한 데이터에 따르면 2020년에는 전 세계적으로 약 8억5천만명이 어떤 형태로든 신장 질환을 앓고 있는데, 이 환자들은 매년 증가하고 있으며[3], 국내에서의 환자도 증가하고 있어 CKD 환자수는 성인9

* 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원사업의 연구결과로 수행되었음 (IITP- 2023-2018-0-01417)

** 한림대 강남성심병원 신장내과 부교수(주저자)

*** 한림대 춘천성심병원 신장내과 부교수(공동저자)

**** (주)지란지교시큐리티 지능정보사업TF장(공동저자)

***** (주)지란지교시큐리티 지능정보사업TF 연구원(공동저자)

***** 호서대학교 기술경영전문대학원 교수(교신저자)

명중 1명 꼴인 460만명으로 집계되고 있다[4].

만성콩팥병은 신장의 사구체여과율에 따라 1기에서부터 5기까지로 나뉜다. 이중 5기 만성콩팥병은 신장 이식 또는 혈액투석, 복막투석과 같은 신대체 요법이 필요한 말기신부전 단계로 정의되며, 대부분의 국가에서 혈액투석은 여전히 주요한 신대체 요법으로 가장 많이 사용되는 투석 방법이다. 혈액투석이 필요한 환자에게 혈관접근로는 절차의 효율성과 성공에 있어서 매우 중요하다. 혈관접근로의 종류에는 중심 정맥 카테터(central venous catheters, 이하 CVC), 동맥-정맥 이식물(arteriovenous graft, 이하 AVG) 및 동정맥루(arteriovenous fistula, 이하 AVF)가 포함된다[5]. AVF는 인공 혈관에 비해 감염, 혈전, 경화 등의 부작용이 적으며, 장기적으로 안정적인 혈관 접근 방법이다. 그러나 AVF의 생성은 수술적인 절차를 필요로 하며, 일부 환자에서는 혈관의 구조적인 문제로 인해 생성이 어려울 수 있다[6]. AVF는 혈액투석환자에서 혈액투석을 위한 중요한 혈관접근로로, 매 투석시 투석바늘로 천자가 되어진다. 매번 혈액투석시 투석바늘로 AVF를 천자하기 때문에, 바늘에 의한 혈관손상이 발생할 수 있으며, 이는 시간이 지남에 따라 협착 및 후속 혈전증으로 이어질 수 있는 일련의 생물학적 변화로 인해 기능 장애가 발생하고, 혈류량이 감소할 수 있다. 이러한 현상은 투석 환자에서 혈액투석의 효율을 저하시키고, 투석을 방해하는 등 임상 상태에 심각한 영향을 미친다. AVF에서 협착 혹은 혈전증이 발생할 경우, 경피적 혈관성형술 및 외과적 혈전제거술을 통해 AVF의 흐름을 회복할 수 있지만, 그렇지 않은 경우 임시 투석 접근을 위해 CVC를 삽입해야 한다. AVF 실패가 환자의 생존, 이환율 및 삶의 질에 미치는 부정적인 영향을 고려하여 최근 가이드라인에서는 AVF 보존을 위한 잠재적 전략에 중점을 두었다. 미국신장재단(National Kidney Foundation, 이하 NKF)의 혈관접근로 진료 지침에서는 혈관접근로의 기능 장애를 감지하기 위

한 주요 모니터링 방법으로 AVF 정기 신체 검사(physical examination) 또는 혈관초음파(vascular ultrasound) 평가를 권장한다. 그러나 혈관접근로를 개선하기 위해 접근로 내 혈류량(Qa)를 측정하고, 정맥 협착 여부를 평가하기 위한 최선의 감시전략(surveillance)의 유용성과 필요성에 대해서는 계속 논란이 되고 있다[7].

현재의 진료지침에 따르면, 혈액투석환자에서 투석혈관의 개통성을 확인하고, 시술 혹은 수술의 필요성 여부는 투석 당일에 시행되는 의료진의 진찰 및 혈액투석시의 동맥압, 정맥압 혹은 혈류량 등의 상황을 보고 판단을 한다. 하지만, 이를 사전에 예측할 수 있다면 환자의 고통감소와 불편을 해소할 수 있고, 충분한 혈류량을 유지함으로써 보다 질 높은 혈액투석 효율 및 투석서비스를 제공할 수 있을 것이다. 특히, 우리나라와 같이 전국에 투석실은 많으나 투석혈관센터가 대도시 대형병원에만 존재하는 경우, 투석환자의 혈관에 문제가 생긴 경우 혈관 수술을 위해 대도시 투석혈관센터까지 이동해야 하는 불편함이 따른다. 이러한 문제를 해결하기 위하여 최근 인공지능을 활용한 예지보전(predictive maintenance)¹⁾ 기법을 활용하여 투석환자의 투석혈관 수술 시기를 예측할 수 있다면 투석관련 의료서비스의 품질을 획기적으로 향상시킬 수 있을 것이다. 이에 본 연구에서는 II장에서 투석혈관에 관련된 선행 연구와 혈관 수술 시기예측에 활용 가능한 인공지능(Artificial Intelligence, 이하 AI) 모델을 살펴보고, III장에서 AI 모델의 개발과정을 검토하고, IV장에서는 AI 모델에 대한 평가와 토의를 수행하고, V장 결론에서는 본 연구의 시사점 및 향후 발전 방향을 기술하고자 한다.

1) 각각의 설비 상태를 정량적으로 파악하여 설비의 이상 상태나 앞으로 일어날 수 있는 사태를 미리 예상하고 적절하게 유지하고 보수하는 일(<https://wordrow.kr/>)

<표 1> 신장학에서의 AI연구

적용 분야	연구 내용	연구자
신장 질환 예측	- AI를 활용한 신장질환의 진단, 예후 예측, 치료 개선	Xie, Chen, and Li[9]
	- 인공지능과 기계 학습의 신장학 분야에서의 적용과 잠재력	Nadkarni[10]
	- 빅데이터와 인공지능을 활용한 신장질환 위험 예측 모델	Yang, Kong, Wang, Zhang, and Zhao[11]
	- AI를 활용하여 신장질환에 대한 진단과 치료 방법을 개선하고 개인 맞춤형 치료를 개발	Badrouchi, Bacha, Hedri, Ben Abdallah, & Abderrahim[12]
	- 인공지능 기술의 신장질환 진단, 예방, 치료, 예후 예측 등에 대한 활용 가능성 탐구	Buczek, Wiśniewski, and Oleszczuk[13]
	- 인공지능과 증강학습을 사용하여 급성신손상(AKI) 예측 및 진단에 대한 새로운 접근법을 제시	Bajaj와Koyner [14]
머신 비전 활용 진단	- CNN을 이용하여 조직 이미지 분석, 병리학적 특징 식별, 질병패턴 예측 연구	Lemley[15]
	- CNN 등 딥러닝을 이용한 이식 생물검사 정확성 향상에 대한 연구	Hermesen, de Bel, Den Boer, Steenberg, and Kers[16]
	- CNN, RNN을 활용하여 당뇨병성 신증후군 환자의 신 생검을 위한 디지털 파이프라인 개발	Ginley, Lutnick, Jen, Fogo, and Jain[17]
	- AI가 신장 초음파 영상에서 다양한 응용 분야에 사용될 수 있는 가능성을 확인	De Jesus-Rodriguez, Morgan, & Sagreiya[18]
AI 유용성 및 잠재력	- 의료 분야에서 인공지능의 활용과 그 잠재력 탐구	Amisha, Malik, Pathania, & Rathaur[19]
	- Big Data와 인공지능이 Nephrology와 Transplantation 분야에 미치는 영향과 잠재력 탐구	Thongprayoon, Kaewput, Kovvuru, Hansrivijit, and Kanduri[20]
	- 소아 신장병 환자의 건강 상태를 평가하고 신체 무게를 정확하게 추정하기 위해 인공지능을 사용	Niel, Bastard, Boussard, Hogan, & Deschênes[21]
	- AI/ML 알고리즘을 사용하여 신장 이식 및 투석 환자의 치료 결과를 개선하기 위한 연구	Burlacu, Iftene, Jugrin, Popa, and Lupu[22]
	- 신장학의 모든 분야에서 신장내과 전문의와 관련된 의료 인공지능에 대한 개요를 제공	Niel과 Bastard [23]
	- 신장 건강과 질병 관리에서 인공지능과 기계학습 기술의 잠재적인 활용 방안 모색	Nadkarni와 Kotanko[24]

II. 관련 연구

2.1 신장학에 인공지능기술 도입 관련 연구

신장학(Nephrology)에서 AI 응용분야는 신장 질환의 위험 인자 예측, 신장 질환의 조기 진단, 신장 이식 후 발생하는 합병증 예측, 신장 질환의 치료 효과 평가, 개인 맞춤형 치료 방법 개발 등으로 볼 수 있다 [8]. 이를 보다 단순화하여 신장 질환 예측, 머신비전

을 활용한 신장질환 조기진단, AI적용 유용성 및 잠재력의 세가지 카테고리로 구분하여 선행연구를 정리한 내용은 <표1>과 같다.

Burlacu, Iftene, Jugrin, Popa, and Lupu[22]는 투석 및 신장 이식 환자에게 AI를 적용한 연구 문헌 검토를 통해 AI의 유용성을 역설하였는데 이를 정리하면 <표 2>와 같다.

<표 2> 투석환자에 대한 AI활용의 유용성

구분	혈액 투석(HD ²⁾)	복막 투석(PD ³⁾)	신장 이식(KT ⁴⁾)
예방	- AI를 활용하여 혈액 투석 임상결과에 대한 위험 프로파일 결정 - 조기 발견을 통해 위험 요인 적시 대응	- AI는 PD기술 실패와 관련된 요인 식별에 도움 - AI는 PD프로세스에서 위험요인 완화를 가능케 함	
진단	- AI활용 대동맥류의 개통성을 추정하면 HD세션 결과와 환자 삶의 질 개선 - AI솔루션은 비싼 진단 절차 대체로 의료비용 절감	- AI는 다양한 유형의 감염과 관련된 특정 바이오마커를 발견 - 이를 통해 조기 적절한 치료 및 ESRD ⁵⁾ 환자의 심각한 감염성 합병증 회피	- AI는 비정상 패턴 감지로 급성 KT 거부반응 관련 크레아티닌 과정 조기 식별, KT환자의 신속한 조치 및 후유증 개선 가능
치방	- AI활용 HD합병증 예방을 위한 약물 복용량 추천 - AI 활용은 합병증 감소 및 약물 사용 절감으로 치료비용 경감	- AI를 활용 투석전 환자를 고수송체 그룹과 저수송체그룹으로 분류하여 요독증 환자에게 더 나은 치료옵션 제공 - 이를 통해 만성신부전 환자의 예후 개선 및 이환율과 사망률 감소	- AI를 통해 타크로리무스 안정용량 정확히 예측하여 이식후 면역억제요법 개선 및 타크로리무스 독성 예방 - 면역억제의 적절한 관리로 이식편 손실을 방지 - AI는 다양한 유형의 식이요법 이점 평가 가능, KT의 삶의 질에 긍정적 영향
예측	- HD에서 사망률과 생존률 예측에 AI 활용 - AI활용 삶의 질, 심혈관 결과 및 투석 중 위험 예측 - 투석중 이벤트를 예측하면 저혈압, 심박수 및 체적 및 변동을 피하여 HD세션의 성공과 비용 효율성 보장	- AI는 체액 과부하, 심부전, 복막염과 같은 합병증 예측 가능 - AI는 뇌졸중 위험 환자를 식별하여 조기 조치 가능, PD입원 감소	- AI는 이식 거부반응, 이식기능저하 및 사망률 예측에 사용 - AI는 이식 전 장기 매칭 도구로 활용 - 이를 통해 보다 현명한 장기 배분과 KT의 전반적인 의료관리 시스템 최적화 가능

2.2. 투석혈관에 대한 연구

투석혈관에 대한 선행 연구는 주로 혈액 투석용 혈관 접근로 경로 개선 방안, AVF 개발과 유지 방안, AVF 실패와 사망률과의 관계 등을 분석하는데 초점이 맞춰져 있고, 투석 혈관 예지보전(predictive maintenance) 관점에서 수술 시기를 미리 예측하는 연구는 드물다.

Polkinghorne과 Lok[25]은 CKD 환자들에게 영구적인 혈관 접근을 확립하는 것의 중요성과 혈관 접근 후 신기능 감소를 예측하는 방법에 대한 논의를 위해 기존의 연구 결과를 종합하여 고찰하고, eGFR(estimated glomerular filtration rate) 궤적 등을

이용하여 혈관 접근 후 신기능 감소를 예측하는 방법을 제시하였다. Escoli, Luz, Santos, & Lobos[26]는 만성신부전 환자의 혈액투석전 혈관 접근로(vascular access, 이하 VA)을 만드는 최적의 시기를 예측하는 연구를 수행하였다. 그들은 202명의 환자를 대상으로 다중변수 로지스틱 회귀분석을 통해서 혈액 투석 시작과 관련된 요인들을 분석하여, 혈관 접근을 만드는 최적의 시기는 환자의 개별적인 상황에 따라 다르지만 eGFR, 당뇨병, 단백뇨, 인, GFR하락 등 5가지 요인이 혈액 투석 시작 시기에 영향을 준다는 것을 밝혀냈다.

Robbin, Greene, Allon, Dember, & Imrey[27]는 혈액투석 환자의 AVF가 잘 발달되는지 예측하기 위해 후기초음파 측정치를 사용하는 방법을 연구하였다. 이를 위해 투석환자의 동정맥루 성숙 연구(Hemodialysis Fistula Maturation Study)에서 수집한 데이터를 분석

2) HD: hemodialysis
3) KT: kidney transplantation
4) PD: peritoneal dialysis
5) ESRD: end stage renal disease

하였고, 후기초음파 측정치가 AVF의 임상적 성숙도를 예측하는 데 유용하다는 것을 확인하였다.

Wan, Zhu, Yang, Zhang, & Cao[28]는 AVF수술 후 혈전증 발생 위험을 낮추기 위한 연구에서 367명의 환자 데이터를 수집 및 분석하여 베라프로스트(Beraprost sodium)와 클로피도그렐(clopidogrel) 비교연구를 통해 베라프로스트가 혈전증 예방에 효과적이라는 것을 입증하였으며, 혈전증 발생 위험 요인으로 나이, 성별, 흡연, 당뇨병, 고혈압 등을 파악하였다. Aljuaid, Alzahrani, Alshehri, Alkhalidi, & Alosaimi[29]는 사우디 아라비아에서 혈액투석 환자들의 AVF 합병증의 발생률과 위험인자를 조사하여 나이, 당뇨병, 고혈압 등이 합병증 발생 위험과 관련이 있음을 밝혔다. Beathard, Litchfield와 Jennings[6]는 2년간의 후향적 연구로, 1,000명 이상의 환자들을 대상으로 AVF의 유지성공률, 합병증 발생률, 그리고 환자 만족도를 평가하고 적절한 환자 선택 방법과 절차적 성공률을 분석하였다. 연구 결과, AVF를 통한 혈관 접근 방법은 높은 유지성공률과 낮은 합병증 발생률을 보였으며, 환자들의 만족도도 높았다. 또한, 적절한 환자 선택과 절차적 성공은 AVF의 성공에 중요한 역할을 한다는 것을 확인하였다.

Masengu, Maxwell, & Hanko[30]는 유럽 7개 국가의 22개 병원에서 2010년 1월부터 2012년 12월까지 AVF 수술을 받은 1,057명의 환자를 대상으로 전향적 연구를 실시하여 기능적 성공률과 실패율을 분석하고, 이를 바탕으로 임상 예측 인자를 도출하였다. 이 연구에서 도출된 임상 예측 인자는 기존의 모델에서 사용되는 인자와 유사하였으며, 이 연구 결과는 AVF의 기능적 성공률을 예측하는 데 있어서 유용한 정보를 제공하는 것으로 나타났다. Farrington, Robbin, Lee, Barker-Finkel, & Allon[31]은 300명의 새로운 AVF를 받은 환자들을 대상으로 한 후향적 분석을 통해, 초기 예측 요소들과 AVF 성숙률 간의 관련성을 평가하였다. 초기 예측 요소들과 AVF 성숙률 간의

관련성을 다중 로지스틱 회귀분석을 통해 평가하여 초기 예측 요소로는 AVF 위치, 동맥 직경, 혈관 흐름 속도 등이 중요한 역할을 하고 새로운 예측 요소로는 혈관 벽 두께, 혈관 내막 세포 수 등이 포함됨을 밝혔다. 이 연구는 AVF 성숙을 예측하는 데 중요한 요소들로 혈액 내 알부민 농도, 혈압, 신장 기능, 나이, 성별, 당뇨병 여부 등을 식별하고, 임상 실무와 환자 결과에 대한 잠재적인 영향을 제시하였다.

Vajdič, Arnol, Gubenšek, Ponikvar, & Buturović[32]은 슬로베니아에서 수행된 국가적 전향적 연구에서 신장 이식 수술을 받은 환자들에서 혈액투석 동안 사용되는 AVF의 장기적인 성공률과 합병증 발생률을 조사하였는데, 이식 후 5년 이상의 장기 간 AVF 성공률은 50% 이상으로 나타났으며, AVF 합병증 발생률은 낮았다. AVF 합병증 발생률과 관련된 예측 인자로는 AVF 위치, 혈액투석 빈도, 혈압 등이 확인되었다.

Gupta, Kumar, Peswani, Suresh, & Peswani[33]는 인도에서 혈액투석을 받는 환자 216명을 대상으로 AVF 생성 후 결과를 조사한 연구에서 AVF 성공률에 영향을 미치는 요인을 로지스틱 분석한 결과 유의미한 것으로는 남성 성별, 직업, 동맥 상태 등이 식별되었고, 연령과 당뇨병 유무는 유의미한 영향을 미치지 않는 것을 확인하였다. Kaller, Arbănași, Mureșan, Voidăzan, & Arbănași[34]는 혈액투석 환자에서 AVF 성공 및 실패의 예측 인자로서 체내 염증 마커, 예후적 영양 지수 및 측정된 혈관 직경의 예측 가치를 조사하기 위해, 루마니아에서 2017년 1월부터 2020년 12월까지 혈액투석을 받은 120명의 환자를 대상으로 후향적 관찰 연구를 수행하였다. 결과적으로, NLR(Neutrophil-to-Lymphocyte Ratio), PLR(Platelet-to-Lymphocyte Ratio), SII(Systemic Immune-Inflammation Index), CRP(C-Reactive Protein), Ca-P product(Calcium-Phosphorus product) 등의 지표는 AVF 성공 및 실패의 예측 인

자로서 유용하며, 이들은 측정된 혈관 직경보다 더 높은 예측 가치를 가진다는 것을 보여주었다.

근래들어 혈관 접근 및 AVF관련 인공지능을 적용한 연구들이 점차 활성화되고 있다. Peralta, Garbelli, Bellocchio, Ponce, & Stuard[7]는 머신러닝을 기반으로 동정맥루 실패 모델(AVF-FM)을 도출하고 검증하였다. AVF-FM은 센터 내 투석 환자의 3개월 내 AVF 실패를 예측하기 위한 XG-Boost 알고리즘을 사용하였고, 이 모델은 네프로케어 유럽 임상 데이터베이스(EuCliD®)에서 일상적으로 수집된 정보를 활용하여 파생 세트(초기 코호트의 70%)에서 학습되었다. 나머지 30%의 기록에 대한 일치 통계 및 보정 차트를 통해 모델 성능을 테스트했는데 위험 예측에 가장 큰 영향을 미치는 변수는 AVF 합병증의 과거 병력이었으며, 투석 용량, 혈류량, 동적 정맥압 및 동맥압의 시간적 패턴을 설명하는 지표들 포함한 접근 재순환 및 기타 기능적 매개변수가 그 뒤를 이었다. 결론적으로 AVF-FM은 의료진의 추가 노력이 필요 없는 일상적으로 수집된 임상 데이터와 센서 데이터를 결합하여 우수한 판별 및 보정 특성을 달성했고 잠재적으로 위험에 기반한 AVF 감시 전략의 개인화를 가능하게 할 수 있었다.

Ota, Nishiura, Ishihara, Adachi, & Yamamoto[35]는 혈액투석 중 발생하는 AVF 소리를 객관적으로 평가하는 새로운 방법 제시하였는데, 2개의 병원에서 수집한 1,200개 이상의 소리 데이터를 이용하여 딥러닝 모델을 학습시킨 실험 결과로 이 방법은 전문가의 평가와 비교하여 높은 정확도를 보였음을 증명하였다. Zonnebeld, Tordoir, Loon, Smet, & Huisman[36]은 혈액투석 환자의 AVF 수술 전에 개별적인 혈액흐름을 예측하기 위해 DUS(Doppler Ultrasound) 검사를 통해 측정된 혈관의 직경과 혈액의 흐름 속도를 기반으로 컴퓨터 시뮬레이션 모델을 사용하였다. AVF 수술 전에 환자별 흐름 예측을 위한 컴퓨터 시뮬레이션 모델을 사용하여 수술 방법을 결정하는 것

이 AVF의 성숙도를 개선하는 데 도움이 된다는 것을 제시하였다.

지금까지 선행연구를 살펴본 바와 같이 혈관 접근의 중요성은 지속적으로 강조되고 있으며, AVF를 비롯한 다양한 투석혈관 관리 기술에 대한 연구가 진행 중이나 AI를 이용하여 투석혈관의 수술시기를 예측한 연구는 거의 없다.

2.3. 분류 및 판별을 위한 AI 알고리즘

머신러닝은 현대 컴퓨팅 세계의 한 분야로서 기계를 지능적으로 만들기 위해 많은 연구가 진행되어 왔다. 전통적인 머신러닝 알고리즘은 많은 응용 분야에 적용되어 왔으며 연구자들은 머신러닝 알고리즘의 정확도를 향상시키기 위해 많은 노력을 기울여 왔다[37]. 기존의 머신러닝 기술은 데이터를 원래 형태로 처리하는데 한계가 있었다. 이러한 방식은 표현을 위해 상당한 이해와 전문 지식이 필요했고, 기능 선택에 세심한 엔지니어링이 필요했다. 딥러닝은 머신러닝의 한 분야로 시스템에 데이터 세트를 입력하면 감지나 분류 등의 사 결정에 필요한 표현을 자동으로 실현하는 일련의 알고리즘을 말한다. 딥러닝을 통해 얻은 결과는 기존의 머신러닝 접근 방식보다 훨씬 개선되었다. 심층 신경망은 시스템이 입력과 출력 간의 복잡한 관계를 학습할 수 있도록 다중 숨겨진 계층 아키텍처의 비선형 모델을 사용한다. 머신러닝에 비해 딥러닝의 장점은 머신러닝처럼 수동으로 추출하거나 수작업으로 피처를 만들 필요가 없다는 것이다. 기존의 머신러닝과 딥러닝은 모두 지도 학습과 비지도 학습이라는 두 가지 유형의 학습 방법론을 사용한다. 지도 학습에서는 데이터를 학습하기 위해 목표 값이 할당되는 반면, 비지도 학습에서는 목표 값이 제공되지 않는다. 지도 학습 접근 방식은 회귀 및 분류 문제 해결에 활용되고 비지도 학습 접근 방식은 연관성 및 클러스터링 문제를 결정하는 데 사용된다[38].

2.3.1. 머신러닝 알고리즘

로지스틱 회귀(Logistic Regression) 분석은 종속 변수가 이항 분포를 따르는 경우에 사용되는 분석 기법이다. 이 기법은 간단하면서도 강력한 분류 모델로, 이진 분류 문제에 대해 높은 예측 성능을 보인다. 하지만, 다중 클래스 분류 문제에 대해서는 성능이 떨어질 수 있다[39-41].

의사결정나무(Decision Tree)는 분류와 회귀 분석에 모두 사용되는 트리 기반 알고리즘이다. 이 알고리즘은 모델의 해석이 용이하고, 비선형적인 관계를 모델링할 수 있어서, 다양한 분류 문제에 적용된다. 하지만, 과적합 문제가 발생할 수 있으며, 예측 성능이 낮은 경우가 있다[39, 40].

랜덤 포레스트는 의사결정나무를 여러 개 결합한 앙상블 기법이다. 이 알고리즘은 여러 개의 의사결정나무를 사용하고, 각각의 의사결정나무는 랜덤하게 선택된 변수들만 사용하여 분류 규칙을 생성한다. 이렇게 생성된 의사결정나무들의 예측 결과를 평균하여 최종 예측 결과를 도출한다. 랜덤 포레스트는 과적합 문제를 해결하고, 예측 성능이 높은 모델로 알려져 있다. 하지만, 모델의 해석이 어렵고, 데이터의 불균형 문제를 해결하기 어렵다는 단점이 있다 [41-43].

서포트 벡터 머신(Support Vector Machine; SVM)은 분류와 회귀 분석에 모두 사용되는 지도 학습 알고리즘이다. 이 알고리즘은 데이터를 고차원 공간으로 매핑하여 클래스 간의 거리를 최대화하는 초평면을 찾고, 이렇게 찾은 초평면을 기준으로 새로운 데이터를 분류한다. 서포트 벡터 머신은 과적합 문제를 해결하고, 예측 성능이 높은 모델로 알려져 있다. 하지만, 데이터의 크기가 커지면 계산 비용이 증가하고, 다중 클래스 분류 문제에 대해서는 성능이 떨어질 수 있다[41, 44].

나이브 베이즈(Naive Bayes algorithm)는 분류에

사용되는 지도 학습 알고리즘이다. 이 알고리즘은 간단하면서도 높은 예측 성능을 보이며, 특히 텍스트 분류 문제에 적용된다. 하지만, 독립 변수 간의 상관 관계를 고려하지 않기 때문에 성능이 떨어지는 경우가 있다[39-41, 43].

K-최근접 이웃(k-Nearest Neighbours)은 분류와 회귀 분석에 모두 사용되는 지도 학습 알고리즘이다. 이 알고리즘은 새로운 데이터와 가장 가까운 K개의 데이터를 찾아, 이들의 클래스를 기반으로 새로운 데이터의 클래스를 예측한다. K-최근접 이웃은 간단하면서도 강력한 분류 모델로, 다양한 분류 문제에 적용된다. 하지만, 데이터의 차원이 높아질수록 예측 성능이 떨어지고, 데이터의 불균형 문제를 해결하기 어렵다는 단점이 있다[45].

<표 3> 분류 문제의 이슈와 해결방법

분류 접근법	문제점	해결법/기술
결정 트리 (ID3 및 C4.5)	<ul style="list-style-type: none"> - 다값 속성 - 복잡한 정보 엔트로피와 더 많은 값의 속성 - 잡음이 많은 데이터 분류 	<ul style="list-style-type: none"> - ID3와 연합 함수(AF) 결합 알고리즘 - 속성 선택 방법 수정, 사전 가지 치기 전략 및 레인포레스트 접근법 - 테일러 공식을 사용한 향상된 알고리즘 - Credal-C4.5 트리
베이지안 네트워크	<ul style="list-style-type: none"> - 속성 조건 밀도 추정 - 추론 (큰 도메인의 이산 및 연속 변수) - 다차원 데이터 	<ul style="list-style-type: none"> - 가우스 커널 함수 - 결정 트리 구조의 조건부 확률 - 탐욕스러운 학습 알고리즘(greedy learning algorithm)
K-최근접 이웃	<ul style="list-style-type: none"> - 공간 요구사항 - 시간 요구사항 - 멀티미디어 데이터 셋에서의 KNN 확장 	<ul style="list-style-type: none"> - 프로토타입 선택 - 특징 선택 및 추출 방법 - R-Tree 인덱스 찾기 - 멀티미디어 KNN 쿼리 처리 시스템
SVM	<ul style="list-style-type: none"> - 거짓 긍정 비율 제어 - 낮은 희소 SVM 분류기 - 다중 라벨 분류 	<ul style="list-style-type: none"> - 위험 지역 SVM (RA-SVM) - 군집 지원 벡터 머신 (CLSVM) - 퍼지 SVMs (FSVMs)

선형 판별 분석(Linear Discriminant)은 지도 학습 알고리즘 중 하나로, 입력 데이터를 가장 잘 분리하는 선형 결정 경계를 찾는 기법이다. 이 알고리즘은 클래스 간 분산과 클래스 내 분산의 비율을 최대화하는 방식으로 결정 경계를 찾는다. 선형 판별 분석은 분류 문제에 적용되며, 특히 이미지 처리 분야에서 널리 사용된다. 하지만, 클래스 간 분산과 클래스 내 분산의 비율이 크게 차이나지 않는 경우에는 성능이 떨어질 수 있다[41, 46].

앙상블 기법은 여러 개의 분류 모델을 결합하여 더욱 강력한 모델을 만드는 기법이다. 이 기법은 다양한 분류 모델을 사용하고, 이들의 예측 결과를 결합하여 최종 예측 결과를 도출한다. 앙상블 기법은 과적합 문제를 해결하고, 예측 성능이 높은 모델로 알려져 있다. 대표적인 앙상블 기법으로는 랜덤 포레스트, 그래디언트 부스팅(Gradient Boosting), 배깅(Bagging) 등이 있다[41, 42, 45].

이상에서 살펴본 전통적인 분류 모형들은 각각 장단점을 가지고 있으며, Sooti와 Awan[47]은 몇가지 분류 모델이 가지고 있는 이슈와 해결방법을 <표 3>과 같이 정리하였다.

2.3.2. 딥러닝 알고리즘

인공 신경망(Artificial Neural Networks; ANN)은 여러 계층의 연결된 노드로 구성된 구조로, 각 노드는 일련의 수학적 연산을 수행한다. 각 노드는 입력 데이터와 가중치의 행렬 곱, 편향의 추가, 그리고 활성화 함수의 처리 과정을 거친다. 활성화 함수로는 종종 시그모이드, ReLU, 탄젠트 하이퍼볼릭 등이 사용된다. 신경망의 학습은 경사 하강법과 같은 최적화 알고리즘을 사용하여 오차를 최소화하는 방향으로 가중치를 조정한다. 이 과정에서 손실 함수가 정의되며, 이 손실 함수의 값이 최소가 되도록 학습한다. 전체 데이터를 한 번 사용하여 학습하는 각 사이클을

에폭(epoch)이라고 한다. 학습률(Learning Rate), 배치 크기(batch Size) 등의 하이퍼파라미터는 모델의 성능에 큰 영향을 미치므로 신중하게 설정해야 한다[48, 49].

합성곱 신경망(Convolutional Neural Networks; CNN)은 가장 널리 사용되는 DL 알고리즘 중 하나로써 이 모델은 1989년 LeCun 등에 의해 보고되었으며, 컴퓨터 비전 분야에서 성공적인 성능을 보여주었다. CNN 모델은 컨볼루션 레이어, 서브 샘플링 레이어(풀링 레이어), 완전 연결 레이어의 세 가지 레이어로 구성된다. 컨볼루션 레이어와 서브 샘플링 레이어는 로컬 수신 필드와 공유 가중치를 적용한다. 여러 계층으로 쌓아 올릴 수 있으며 마지막 단계에서 완전 연결 계층을 통해 분류 작업을 수행한다. CNN은 특징 추출과 분류에 탁월하여 이미지 인식, 분류, 비디오 인식 분야에서 널리 사용되고 있다[38, 50, 51].


순환 신경망(Recurrent Neural Networks; RNN)은 순차적 데이터를 처리하기 위한 신경망 구조로, 각 시간 단계에서 이전 시간 단계의 출력이 다음 시간 단계의 입력으로 사용된다. 이렇게 순환적인 연결로 인해 과거의 정보가 현재의 연산에 영향을 미친다. 그러나 기본 RNN은 시퀀스가 길어질수록 과거의 정보가 손실되는 경향이 있어, 실제 작업에서는 LSTM이나 GRU와 같은 변형된 구조가 주로 사용된다. RNN은 자연어 처리, 음성 인식, 시계열 예측 등에서 활용된다[50-52].

롱 숏 텀 메모리(Long Short-Term Memory; LSTM)은 RNN의 한 변형으로 장기적인 의존성을 가진 데이터를 효과적으로 처리할 수 있다. LSTM은 여러 게이트를 통해 정보의 흐름을 조절한다. 이러한 게이트들은 어떤 정보를 저장하거나, 삭제하거나, 출력할지 결정하는 역할을 한다. LSTM은 내부의 셀 상태를 통해 정보를 장기간 유지할 수 있으며, 이는 복잡한 시퀀스 데이터에서 중요한 패턴을 포착하는 데 큰 도움이 된다[52, 53].

III. AI활용 투석환자 혈관수술 시기 예측 모델 개발

3.1. 혈관 수술시기 예측 목표 모델

AI를 활용한 투석환자 혈관 수술시기 예측시스템은 <그림 1>과 같이 과거에 환자들이 투석을 받으면서 측정된 혈류 및 정맥압 등의 검사 결과데이터와 실제로 수술 시행 여부 데이터를 기반으로 AI모델을 개발하고, 개발된 AI모델을 활용하여 내원 환자의 검사결과와 혈액투석기에서 수집된 데이터를 기반으로 추후 혈관의 수술 여부를 예측하는 시스템이다.



<그림 1> AI활용 투석혈관 수술시기 예측시스템 목표 모델


3.2. 데이터 분석 및 전처리

AI모델 개발을 위한 학습용 데이터는 <표 4>와 같이 환자 식별자 해시값, 성별, 생년, 투석일, 정맥압(Venous Pressure; VP), 혈류량(Blood Flow), 투석효과 평가용 지표인 ktnv, 투석전 혈압(predsbp), 투석전 이완기 혈압(predb), 투석전 맥박수(prepls), 혈전제거(수술)시행여부, 혈전제거 수술일 목록, 혈전제거(시술)시행여부, 혈전제거 시술일 목록으로 구분되어 있다.

검사 데이터는 <그림 2>와 같이 수술(또는 시술) 받은 데이터와 수술(또는 시술) 받지 않은 데이터 그룹으로 구분하여 학습용 데이터를 생성한다.

<표 4> 학습용 데이터 속성 구분

구분	설명
hash	환자 구분 식별자 해시값 (가명화)
성별	환자의 성별
생년	환자의 출생 년도
실사일	혈관 투석 실시일
vp(venous pressure)	투석 시, 혈액이 투석기로 들어가는 정맥의 압력
blood flow	투석 시, 혈액이 투석기를 통과하는 속도나 양 혈액이 투석기에 제거되고 정화되는 속도
ktnv(=kt/v)	투석의 효과를 평가하기 위해 사용되는 지표
presbp	투석 전 혈압을 의미
predb	투석 전 이완기 혈압
prepls	투석 전 맥박수
혈전제거(수술) 시행여부	혈전제거 수술 시행 여부, 한번이라도 시행하면 'Y'
혈전제거(수술) 시행리스트	혈전제거 수술일 목록
혈전제거(시술) 시행여부	혈전제거 시술 시행 여부, 한번이라도 시행하면 'Y'
혈전제거(시술) 시행리스트	혈전제거 시술일 목록



<그림 2> 데이터 전처리 과정

학습용 데이터 셋은 2006년 1월부터 2023년 5월까지의 31만건 데이터 중에서 이상치와 결측치를 제거한 23만건을 사용하였다. 학습데이터 중 혈액 투석기의 데이터는 기기간 직접 연동을 통하여 수집된 것이 아닌 의료진이 입력한 값이라 오류값이 상대적으로 많이 포함되어 있기 때문에 입력 변수로 사용되는 5 가지 항목은 <표 5>를 참조하여 정상 범위를 벗어난 데이터를 결측치로 처리하였다. 또한, 성별은 레이블 인코딩을 진행하고, 생년은 나이로 변환하였으며, 혈전제거 시행리스트와 혈전제거 시행여부를 합쳐 출

력 레이블을 생성하였다.

<표 5> 투석기 데이터의 정상 범위

구분	정상 범위
vp	vp < 300
blood flow	250 < blood flow < 330
presbp	70 < presbp < 250
predbp	30 < predbp < 200
prepls	30 < prepls < 200

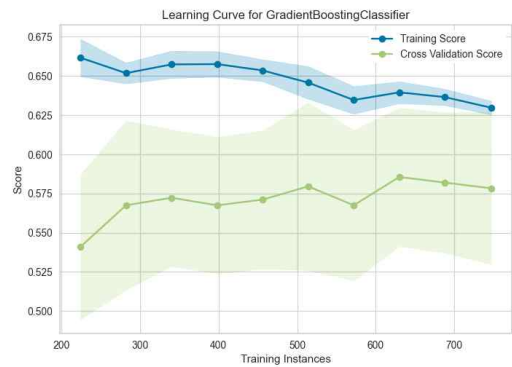
3.3. 머신러닝 예측 모델 생성

머신러닝 모델은 혈액 투석기에서 측정된 환자의 특성을 기준으로 시술/수술여부를 판단하는 이진분류 모델을 적용하였다. Pytorch에서 제공하는 이진분류 모델을 학습시킨 결과는 <표 6>과 같다.

<표 6> 머신러닝 이진분류 모델 성능

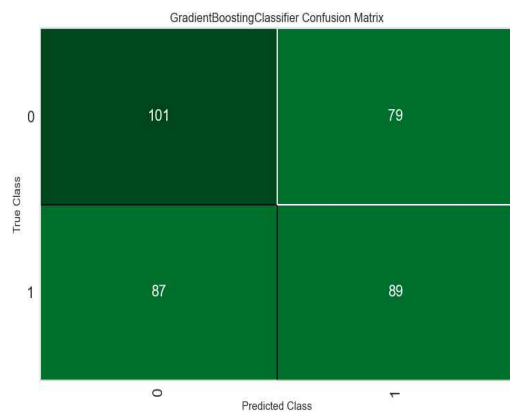
Model	Accuracy	Recall	Precision	F1
Gradient Boosting Classifier	0.5783	0.5537	0.5814	0.5642
Extreme Gradient Boosting	0.5735	0.5537	0.5738	0.5606
Light Gradient Boosting Machine	0.5723	0.5512	0.5727	0.5589
Decision Tree Classifier	0.5651	0.5049	0.5728	0.5336
Extra Trees Classifier	0.5651	0.5049	0.5728	0.5336
Random Forest Classifier	0.5602	0.5268	0.5634	0.5421
Ada Boost Classifier	0.5602	0.5366	0.563	0.5462
Logistic Regression	0.5446	0.439	0.5475	0.4843
Ridge Classifier	0.5446	0.439	0.5475	0.4843
Linear Discriminant Analysis	0.5446	0.439	0.5475	0.4843
Naive Bayes	0.5361	0.3805	0.5457	0.4442
Quadratic Discriminant Analysis	0.5361	0.3805	0.5457	0.4442
K Neighbors Classifier	0.5349	0.5195	0.5304	0.522
SVM - Linear Kernel	0.5012	0.5927	0.2976	0.3962

14개 모델 중에서는 Gradient Boosting Classifier가 정확도 0.5783, 재현율 0.5537, 정밀도 0.5814, F1-Score 0.5642로 가장 높은 성능을 보이고 있으나, 대부분의 알고리즘이 0.5 전후의 낮은 성능에 머물고 있다. <그림 3>의 학습 곡선을 확인한 결과도 학습 데이터가 증가해도 성능향상이 이루어지지 않음을 알 수 있다.



<그림 3> Gradient Boosting Classifier의 학습곡선

혼동 행렬(Confusion Matrix)을 통해서 확인한 결과도 <그림 4>에서 보는 바와 같이 분류의 변별력이 떨어지고 있다.



<그림 4> Gradient Boosting Classifier Confusion Matrix

하이퍼파라미터 조정을 통한 튜닝까지 시도하였으나 성능의 향상을 기대할 수 없어서 결국 딥러닝 모델을 적용하기로 하였다.

3.4. 딥러닝 예측 모델 생성

딥러닝 모델 적용을 위하여 데이터에 대한 추가적인 전처리를 수행하였다. 시술/수술일과 가장 가까운 최근의 실시일을 매핑하고, 매핑된 시술일과 실시일 사이의 날짜 간격이 2주보다 크면 매핑을 취소하였다. 실시일 기준으로 2주 이내의 이전 5개의 측정 데이터(실시일 포함)를 그룹으로 생성하고, 최소 1개에서 최대 5개 묶음으로 MultiIndex 컬럼을 생성하였다. 1개로 구성된 MultiIndex는 시계열 신경망 구성에 활용이 어려워 학습데이터에서 결측치로 처리하였다. 시술/수술하지 않은 데이터는 시술/수술하지 않은 투석일을 기준으로 2주 이내의 5개의 측정 데이터를 그룹으로 생성하여 신경망의 입력값으로 사용하였다.

딥러닝 모델의 특정 알고리즘 선정을 위한 초기 고려사항으로 혈관 시술/수술을 받는 환자의 혈관 상태는 시간이 지남에 따라 서서히 악화되는 점에 착안하여 RNN기반의 모델을 검토하였다. 충분히 많지 않은 학습 데이터를 감안하여 GRU모델을 검토하였으나, 학습과정에서 LSTM모델이 보다 좋은 성능을 보여줌으로써 최종 후보 모델로 LSTM을 선정하였다.

학습데이터 후보 항목은 vp, blood flow, presbp, predbp, prepls, sex, age 등으로 vp, blood flow는 시술 여부에 중요 판단 요소로 고정하고, 나머지 presbp, predbp, prepls, sex, age에 대한 조합을 통해 31개의 데이터셋을 생성하였다. 학습 데이터에서 1개의 그룹은 최소 2개에서 최대 5개의 측정 데이터로 구성되었고 측정데이터 수는 5보다 작은 경우도 있으므로 zero padding 추가를 통해 최대 5개로 구성하였다.

학습용 데이터는 총 11,378건이며, 이중 시술/수술 받은 것으로 데이터는 817건, 시술/수술받지 않은 데이터는 10,561건인데 클래스의 편향이 심하여 시술/수술 데이터와 시술/수 받지 않은 데이터 비율은 1:2로 선별 구성하였다. 또한, 학습용, 검증용, 테스트용 데이터 셋은 각각 80%, 10%, 10%의 비율로 적용하였다.

AI모델은 PyTorch 프레임워크에서 LSTM모델을 사용하였다. LSTM에서 사용한 기본 속성은 <표 7>과 같으며, 하이퍼파라미터는 <표 8>과 같다.

<표 7> LSTM모델 기본 속성

구분	이름	비고
criterion	CrossEntropyLoss	loss 함수
optimizer	Adam	
성능 평가	Accuracy, F1 score	

<표 8> LSTM모델의 하이퍼파라미터

구분	설명	비고
input_size	입력값 컬럼에 따라 달라짐	
batch_size	배치사이즈	16
hidden_size	RNN 히든 사이즈	256
layer_size	RNN 레이어 개수	2
epoch	epoch 개수	50
LR	Learning Rate	0.001, 0.0001, 0.0005
dropout	RNN dropout 설정	0.25
bidirectional	양방향	True


AI모델 학습은 앞서 생성한 31개의 데이터셋에 3가지 LR값을 적용하여 총 93개의 후보 모델을 구성하였다. 학습결과 성능이 우수한 상위 10개의 모델은 <표 9>와 같이 성능지표가 평균적으로 0.82~0.87 수준으로 측정되었다.

6) 구조: [그룹 포함된 측정데이터 수, 데이터셋 조합개수]

<표 9> epoch=50에서 상위 10개 모델의 성능지표

학습순서	데이터셋	LR	Accuracy	Precision	Recall	F1_score
90	30	0.0005	0.8725	0.8171	0.9437	0.8758
60	20	0.0005	0.8658	0.8312	0.9014	0.8649
89	30	0.0001	0.8456	0.7791	0.9437	0.8535
80	27	0.0001	0.8523	0.8451	0.8451	0.8451
59	20	0.0001	0.8322	0.7805	0.9014	0.8366
77	26	0.0001	0.8322	0.7805	0.9014	0.8366
41	14	0.0001	0.8255	0.7586	0.9296	0.8354
86	29	0.0001	0.8188	0.7391	0.9577	0.8343
68	23	0.0001	0.8121	0.7216	0.9859	0.8333
69	23	0.0005	0.8255	0.7848	0.8732	0.8266

가장 좋은 성능을 보여준 30번 데이터셋(vp, blood flow, predbp, prepls, sex, age)에 LR 0.0005 적용시의 성능지표 변화 그래프는 <그림 5>에서 보는 바와 같이 epoch 50까지 지속적으로 손실감소 및 정확도 향상을 확인할 수 있다.



<그림 5> epoch=50 수준에서 30번 데이터셋의 성능지표 변화 그래프


AI모델 성능 튜닝을 위하여 epoch 파라미터를 변화시켜 가면서 실험을 계속하였고, epoch=100에서 상

위 10개 모델의 성능지표는 <표 10>과 같으며, epoch=50 대비 전체적으로 성능이 향상된 것을 볼 수 있다.

<표 10> epoch=100에서 상위 10개 모델의 성능지표

학습순서	데이터셋	LR	Accuracy	Precision	Recall	F1_score
80	27	0.0001	0.9195	0.9155	0.9155	0.9155
90	30	0.0005	0.8725	0.8171	0.9437	0.8758
69	23	0.0005	0.8725	0.8171	0.9437	0.8758
60	20	0.0005	0.8658	0.8312	0.9014	0.8649
89	30	0.0001	0.8456	0.7791	0.9437	0.8535
59	20	0.0001	0.8322	0.7805	0.9014	0.8366
41	14	0.0001	0.8255	0.7586	0.9296	0.8354
86	29	0.0001	0.8188	0.7391	0.9577	0.8343
68	23	0.0001	0.8121	0.7216	0.9859	0.8333
77	26	0.0001	0.7987	0.7253	0.9296	0.8148

Epoch=100에서 가장 좋은 성능을 보여준 27번 데이터셋(vp, blood flow, presbp, predbp, prepls, age)에 LR 0.0001 적용시의 성능지표 변화 그래프는 <그림 6>에서 보는 바와 같이 epoch 100까지 지속적인



<그림 6> epoch=100 수준에서 27번 데이터셋의 성능지표 변화 그래프

로 손실감소 및 정확도 향상을 확인할 수 있다.

하이퍼파라미터 값 변화를 통한 튜닝 과정을 거쳐 최종적으로 Accuracy, Precision, Recall, F1-Score가 모두 0.91 이상인 27번 데이터 셋의 성능이 우수함을 확인하여 최종 모델로 선정하였다.

IV. 토의 및 평가

27번 데이터셋의 성능지표는 모두 0.91이상으로 우수한 성능을 보이고 있다. 상위 10개의 데이터셋에는 presbp, prepls, age 항목이 혈관 시술/수술 예측에 영향을 미치는 주요인자로 다수 포함되어 있다. 학습 데이터로 사용된 측정데이터는 투석이 시작된 이후에 투석기에서 발생하는 데이터를 의료진이 입력한 것을 사용하였으므로 입력 오류 및 측정값이 해당 환자 상태의 최적 대표값이 아닐 수 있다는 한계가 있다. 예측 모델의 정확성을 높이기 위해서는 현행 최대 5회의 측정에서 측정 주기를 단축시켜 추가적인 데이터 측정 및 수집을 검토할 필요가 있다. 투석 1회의 1번의 입력값을 통해서도 일정 수준의 정확도를 보이는 만큼 투석 1회의 최저, 최고, 평균 입력값을 활용하는 방안도 검토가 필요하다. 가장 좋은 방법은 투석기에서 발생된 데이터를 실시간 또는 준 실시간으로 연동을 하여 투석시간 동안의 변화되는 데이터를 충분히 확보하여 활용하는 것이다.

그럼에도 불구하고 현재 확보된 데이터를 활용하여 혈관 시술/수술 시기를 예측하는 AI모델을 개발한 결과 머신러닝 알고리즘에서는 성능이 좋지 않았으나, 딥러닝 모델에서는 좋은 성능을 보이는 모델을 확보함으로써 투석실에 실제 적용 가능성을 높였다는 것은 본 연구의 중요한 성과라고 판단된다.

근래들어 급속도로 발전하고 있는 기계 학습 알고리즘은 일반 산업계 뿐만 아니라 의료 분야에서도 다양한 예측 모델을 생성하는 데 활용될 수 있다. 기존

의 연구에서는 이미 로지스틱 회귀, 의사결정 나무, SVM, 신경망 등의 알고리즘을 사용하여 당뇨병, 심장 질환, 암 등의 질병을 예측하는데 활용한 사례가 있다. 또한, 랜덤 포레스트와 같은 알고리즘은 다양한 입력 변수를 사용하여 분류 모델을 생성하며, 이를 통해 질병 예측에 대한 정확도를 높일 수 있다. 그러나, 기계 학습 알고리즘의 의료 적용 가능성은 여전히 제한적이다. 기계 학습 알고리즘은 데이터의 품질과 양에 크게 의존하며, 데이터의 부족, 노이즈, 이상치 등의 문제가 발생할 경우 예측 성능이 저하될 수 있다.

또한, 기계 학습 알고리즘은 예측 결과에 대한 설명을 제공하지 않으므로, 의료 전문가들이 예측 결과를 이해하고 검증하는 데 어려움을 겪을 수 있다. 따라서, 기계 학습 알고리즘의 의료 적용 가능성을 높이기 위해서는 데이터의 품질과 양을 보장하고, 예측 결과에 대한 설명을 제공하는 방법 등에 대한 연구가 필요하다. 최근 이를 해결하기 위한 방안으로 설명가능한 AI(XAI)에 대한 연구가 활발히 진행되고 있다. XAI를 적용하여 의료 분야에서 더 나은 의료 결정을 내리는 방법들을 연구하고, 이를 위한 도구와 기술들을 개발하는 것이 필요하다. XAI를 적용하여 예측 모델의 성능을 개선하는 방법들을 연구해야 하며[54] 설명 가능성이 중요한 의료 결정에 AI 기술을 적용할 때는 모델의 투명성과 신뢰성을 보장하는 것이 중요하다[55].

추가적으로 기계 학습 알고리즘의 의료 적용가능성을 높이기 위해서는 근래들어 더욱 강조되고 있는 개인정보 보호 문제에 대한 고려도 필요하다. 의료 데이터는 개인정보 보호에 대한 엄격한 규제를 받으며, 이를 준수하지 않을 경우 법적인 문제가 발생할 수 있다. 따라서, 기계 학습 알고리즘을 적용할 때에는 개인정보 보호 규정을 준수하고, 의료 전문가들과의 협력을 통해 안전하고 효과적인 의료 서비스를 제공할 수 있도록 노력하는 것이 중요하다.

또한, 기계 학습 알고리즘의 의료 적용 가능성을 높이기 위해서는 다양한 분야의 전문가들과의 협력이 필요하다. 의료 데이터는 복잡하고 다양한 정보를 포함하며, 이를 이해하고 해석하는 것은 의료 전문가들의 지식과 경험이 필요하다. 따라서, 기계 학습 알고리즘을 적용할 때에는 의료 전문가들과의 협력을 통해 데이터의 특성을 이해하고, 예측 모델의 설계와 검증을 수행해야 한다. 또한, 기계 학습 알고리즘을 적용한 결과를 의료 전문가들과 공유하고, 이를 토대로 의료 서비스를 개선하는 방법에 대한 연구도 필요하다[41].

V. 결론 및 시사점

본 연구에서는 투석환자에 대한 혈관 접근의 중요성을 인식하고, 일반 산업계에서 활발히 응용되고 있는 예지보전 기법을 이용하여 혈관의 시술/수술 시기를 예측하는 AI 알고리즘을 개발하였다. 투석기기에서 발생한 데이터를 의료진이 수작업으로 입력함으로써 발생하는 검사 시점의 차이, 입력 오류 등으로 입력 데이터의 불충분으로 머신러닝 알고리즘으로는 성능이 너무 낮게 나와서 적절한 모델을 생성할 수 없었다. 그러나, 딥러닝의 LSTM알고리즘을 적용하고 지속적인 튜닝을 하여 정확도, 정밀도, 재현율, F-Score 모두 0.91 이상의 성능을 내는 우수한 모델을 개발하였다. 테스트셋에 대한 검증에서도 성능지표가 0.9 이상을 보이고 있어서 개발된 모델의 타당성도 입증되었다.

선행연구들이 혈관 접근 측면에서 AVF의 생성 및 보존, 관련 합병증 및 사망률 예측 등에 연구의 초점이 맞춰져 있다면 본 연구는 투석혈관의 시술 및 수술시기를 예측하는 데 초점을 맞추고 있어서 기존의 연구와는 차별성이 있다. 우수한 성능의 모델을 개발함으로써 의료현장에 적용 가능성을 높였으나, 실제

투석실에서 적용을 통한 현실적인 검증이 과제로 남아 있으며, 실제 검증시 AI모델 학습에 사용된 입력 변수의 수집 방식 한계로 모델의 정확성이 저하될 수 있다는 한계를 가지고 있다.

후속 연구에서는 투석기기에서 발생된 시시각각의 데이터를 직접 연동하여 수집하고 이를 충분히 활용하여 보다 정교한 AI모델을 생성한다면 투석실 현장 적용가능성 및 그 효과를 증진할 수 있을 것이다. 아울러 타 의료분야 대비 AI적용 연구가 상대적으로 덜 활발한 신장분야에 AI를 활용하는 연구가 더욱 활성화될 필요가 있으며, 선행 연구들에서 공통적으로 지적하고 있는 개인정보보호 및 윤리 문제, 법적/제도적 규제, AI가 제시한 결과의 설명가능성 등에 대한 고려가 항상 함께 수반되어야 함을 명심해야 할 것이다.

참고문헌

- [1] 김서영, “만성신부전증 환자 4년새 36% 증가...4명 중 3명이 60대 이상,” 연합뉴스, <https://www.yna.co.kr/view/AKR20220310074000530>, 2022.03.10.
- [2] Malkina, A., “만성 신장 질환,” <https://www.msmanuals.com/ko-kr/%ED%99%88/%EC%8B%A0%EC%9E%A5-%EB%B0%8F-%EC%9A%94%EB%A1%9C-%EC%A7%88%ED%99%98/%EC%8B%A0%EB%B6%80%EC%A0%84/%EB%A7%8C%EC%84%B1-%EC%8B%A0%EC%9E%A5-%EC%A7%88%ED%99%98-ckd>, 2023.03.09.
- [3] SUNPAPER, “혈액 투석 및 복막 투석 제품별 시장 분석(기계, 투석기, 혈통, 카테터, 농축액 및 소모품) 유형별(일반, 데일리 및 야행성); 및 최종 사용자별(병원, 투석 센터 및 홈 케어 설정) - 글로벌 공급 및 수요 분석 및 기회 전망 2022-2031,”

- <https://www.sunpaper.co.kr/reports/hemodialysis-and-peritoneal-dialysis-market-analysis/544/>, 2022.
- [4] 임세형, “국내 CKD 환자 460만명 연평균 8.7% 증가 중,” The MOST, <http://www.mostonline.co.kr/news/articleView.html?idxno=96959>, 2021.04.16.
- [5] Barcena, A. J. R., Perez, J. V. D., Liu, O., Mu, A., Heralde, F. M., 3rd, Huang, S. Y., & Melancon, M. P., “Localized Perivascular Therapeutic Approaches to Inhibit Venous Neointimal Hyperplasia in Arteriovenous Fistula Access for Hemodialysis Use,” *Biomolecules*, Vol.12, No.10, 2022.
- [6] Beathard, G. A., Litchfield, T., & Jennings, W. C., “Two-year cumulative patency of endovascular arteriovenous fistula,” *J Vasc Access*, Vol.21, No.3, 2020, pp.350-356.
- [7] Peralta, R., Garbelli, M., Bellocchio, F., Ponce, P., Stuard, S., Lodigiani, M., ... Neri, L., “Development and Validation of a Machine Learning Model Predicting Arteriovenous Fistula Failure in a Large Network of Dialysis Clinics,” *Int J Environ Res Public Health*, Vol.18, No.23, 2021.
- [8] Jiang, J., Chan, L., & Nadkarni, G. N., “The promise of artificial intelligence for kidney pathophysiology,” *Curr Opin Nephrol Hypertens*, Vol.31, No.4, 2022, pp.380-386.
- [9] Xie, G., Chen, T., Li, Y., Chen, T., Li, X., & Liu, Z., “Artificial Intelligence in Nephrology: How Can Artificial Intelligence Augment Nephrologists’ Intelligence?,” *Kidney Dis (Basel)*, Vol.6, No.1, 2020, pp.1-6.
- [10] Nadkarni, G. N., & Kotanko, P., “The Future of Artificial Intelligence and Machine Learning in Kidney Health and Disease,” *Adv Chronic Kidney Dis*, Vol.29, No.5, 2022, pp.425-426.
- [11] Yang, C., Kong, G., Wang, L., Zhang, L., & Zhao, M. H., “Big data in nephrology: Are we ready for the change?,” *Nephrology (Carlton)*, Vol.24, No.11, 2019, pp.1097-1102.
- [12] Badrouchi, S., Bacha, M. M., Hedri, H., Ben Abdallah, T., & Abderrahim, E., “Toward generalizing the use of artificial intelligence in nephrology and kidney transplantation,” *J Nephrol*, Vol.36, No.4, 2023, pp.1087-1100.
- [13] Buczek, W., Wiśniewski, M., Oleszczuk, R., Kozłowska, I., & Orczykowski, M., “The use of artificial intelligence in nephrology,” *Journal of Education, Health and Sport*, Vol.12, No.9, 2022, pp. 701-711.
- [14] Bajaj, T., & Koyner, J. L., “Cautious Optimism: Artificial Intelligence and Acute Kidney Injury,” *Clin J Am Soc Nephrol*, 2023.
- [15] Lemley, K. V., “Machine Learning Comes to Nephrology,” *J Am Soc Nephrol*, Vol.30, No.10, 2019, pp.1780-1781.
- [16] Hermsen, M., de Bel, T., den Boer, M., Steenbergen, E. J., Kers, J., Florquin, S., ... van der Laak, J., “Deep Learning-Based Histopathologic Assessment of Kidney Tissue,” *J Am Soc Nephrol*, Vol.30, No.10, 2019, pp. 1968-1979.
- [17] Ginley, B., Lutnick, B., Jen, K. Y., Fogo, A. B., Jain, S., Rosenberg, A., ... Sarder, P., “Computational Segmentation and Classification of Diabetic Glomerulosclerosis,” *J Am Soc Nephrol*, Vol.30, No.10, 2019, pp.1953-1967.
- [18] De Jesus-Rodriguez, H. J., Morgan, M. A., &

- Sagreiya, H., "Deep Learning in Kidney Ultrasound: Overview, Frontiers, and Challenges," *Adv Chronic Kidney Dis*, Vol.28, No.3, 2021, pp.262-269.
- [19] Amisha, Malik, P., Pathania, M., & Rathaur, V. K., "Overview of artificial intelligence in medicine," *J Family Med Prim Care*, Vol.8, No.7, 2019, pp.2328-2331.
- [20] Thongprayoon, C., Kaewput, W., Kovvuru, K., Hansrivijit, P., Kanduri, S. R., Bathini, T., ... Cheungpasitporn, W., "Promises of Big Data and Artificial Intelligence in Nephrology and Transplantation," *J Clin Med*, Vol.9, No.4, 2020.
- [21] Niel, O., Bastard, P., Boussard, C., Hogan, J., Kwon, T., & Deschenes, G., "Artificial intelligence outperforms experienced nephrologists to assess dry weight in pediatric patients on chronic hemodialysis," *Pediatr Nephrol*, Vol.33, No.10, 2018, pp.1799-1803.
- [22] Burlacu, A., Iftene, A., Jugrin, D., Popa, I. V., Lupu, P. M., Vlad, C., & Covic, A., "Using Artificial Intelligence Resources in Dialysis and Kidney Transplant Patients: A Literature Review," *Biomed Res Int*, 2020.
- [23] Niel, O., & Bastard, P., "Artificial intelligence in nephrology: core concepts, clinical applications, and perspectives," *American journal of kidney diseases*, Vol.74, No.6, 2019, pp.803-810.
- [24] Nadkarni, G. N., "Introduction to Artificial Intelligence and Machine Learning in Nephrology," *Clin J Am Soc Nephrol*, Vol.18, No.3, 2023, pp.392-393.
- [25] Polkinghorne, K. R., & Lok, C. E., "Can We Predict the Unpredictable after Vascular Access Creation?," *Clin J Am Soc Nephrol*, Vol.11, No.10, 2016, pp.1729-1731.
- [26] Escoli, R., Luz, I., Santos, P., & Lobos, A. V., "Predialysis vascular access creation: to whom and when," *Port J Nephrol Hypert*, Vol.31, No.3, 2017, pp.162-166.
- [27] Robbin, M. L., Greene, T., Allon, M., Dember, L. M., Imrey, P. B., Cheung, A. K., ... Hemodialysis Fistula Maturation Study, G., "Prediction of Arteriovenous Fistula Clinical Maturation from Postoperative Ultrasound Measurements: Findings from the Hemodialysis Fistula Maturation Study," *J Am Soc Nephrol*, Vol.29, No.11, 2018, pp.2735-2744.
- [28] Wan, Z., Zhu, Y., Yang, R., Zhang, Y., Yang, C., Cao, L., ... Xiong, M., "Beraprost sodium versus clopidogrel for preventing vascular thromboembolic events of arteriovenous fistula in uraemic patients: a retrospective study with a mean 3-year follow-up," *J Int Med Res*, Vol.47, No.1, 2019, pp.252-264.
- [29] Aljuaid, M. M., Alzahrani, N. N., Alshehri, A. A., Alkhaldi, L. H., Alosaimi, F. S., Aljuaid, N. W., ... Atalla, A. A., "Complications of arteriovenous fistula in dialysis patients: Incidence and risk factors in Taif city, KSA," *J Family Med Prim Care*, Vol.9, No.1, 2020, pp.407-411.
- [30] Masengu, A., Maxwell, A. P., & Hanko, J. B., "Investigating clinical predictors of arteriovenous fistula functional patency in a European cohort," *Clin Kidney J*, Vol.9, No.1, 2016, pp.142-147.
- [31] Farrington, C. A., Robbin, M. L., Lee, T., Barker-Finkel, J., & Allon, M., "Early Predictors of Arteriovenous Fistula Maturation: A Novel

- Perspective on an Enduring Problem," *J Am Soc Nephrol*, Vol.31, No.7, 2020, pp.1617-1627.
- [32] Vajdic Trampuz, B., Arnol, M., Gubensek, J., Ponikvar, R., & Buturovic Ponikvar, J., "A national cohort study on hemodialysis arteriovenous fistulas after kidney transplantation - long-term patency, use and complications," *BMC Nephrol*, Vol.22, No.1, 2021.
- [33] Gupta, A., Kumar, V., Peswani, A. R., & Suresh, A., "Outcomes of Arteriovenous Fistula Creation in Patients Undergoing Hemodialysis: An Indian Experience," *Cureus*, Vol.14, No.1, 2022.
- [34] Kaller, R., Arbanasi, E. M., Muresan, A. V., Voidazan, S., Arbanasi, E. M., Horvath, E., ... Russu, E., "The Predictive Value of Systemic Inflammatory Markers, the Prognostic Nutritional Index, and Measured Vessels' Diameters in Arteriovenous Fistula Maturation Failure," *Life (Basel)*, Vol.12, No.9, 2022.
- [35] Ota, K., Nishiura, Y., Ishihara, S., Adachi, H., Yamamoto, T., & Hamano, T., "Evaluation of Hemodialysis Arteriovenous Bruit by Deep Learning," *Sensors (Basel)*, Vol.20, No.17, 2020.
- [36] Zonbeld, N., Tordoir, J. H. M., van Loon, M. M., de Smet, A., Huisman, L. C., Cuyper, P. W. M., ... Shunt Simulation Study, G., "Pre-operative Patient Specific Flow Predictions to Improve Haemodialysis Arteriovenous Fistula Maturation (Shunt Simulation Study): A Randomised Controlled Trial," *Eur J Vasc Endovasc Surg*, Vol.60, No.1, 2020, pp.98-106.
- [37] Shinde, P. P., & Shah, S., "A review of machine learning and deep learning applications," 2018 Fourth international conference on computing communication control and automation (ICCUBEA), 2018.
- [38] Chauhan, N. K., & Singh, K., "A review on conventional machine learning vs deep learning," 2018 International conference on computing, power and communication technologies (GUCON), 2018.
- [39] F.Y, O., J.E.T, A., O, A., J. O, H., O, O., & J, A., "Supervised Machine Learning Algorithms: Classification and Comparison," *International Journal of Computer Trends and Technology*, Vol.48, No.3, 2017, pp.128-138.
- [40] Nasteski, V., "An overview of the supervised machine learning methods," *Horizons.B*, Vol.4, 2017, pp.51-62.
- [41] Miller, A., Panneerselvam, J., & Liu, L., "A review of regression and classification techniques for analysis of common and rare variants and gene-environmental factors," *Neurocomputing*, Vol.489, 2022, pp.466-485.
- [42] Alzubi, J., Nayyar, A., & Kumar, A., "Machine learning from theory to algorithms: an overview," *Journal of physics: conference series*, 2018.
- [43] Jackins, V., Vimal, S., Kaliappan, M., & Lee, M. Y., "AI-based smart prediction of clinical disease using random forest classifier and Naive Bayes," *The Journal of Supercomputing*, Vol.77, No.5, 2020, pp.5198-5219.
- [44] Abdulkareem, N. M., & Abdulazeez, A. M., "Machine learning classification based on Radom Forest Algorithm: A review," *International journal of science and business*, Vol.5, No.2, 2021, pp.128-142.
- [45] Maxwell, A. E., Warner, T. A., & Fang, F.,

"Implementation of machine-learning classification in remote sensing: an applied review," *International Journal of Remote Sensing*, Vol.39, No.9, 2018, pp.2784-2817.

[46] Zhu, F., Gao, J., Yang, J., & Ye, N., "Neighborhood linear discriminant analysis," *Pattern Recognition*, Vol.123, 2022.

[47] Soofi, A. A., & Awan, A., "Classification techniques in machine learning: applications and issues," *Journal of Basic & Applied Sciences*, Vol.13, No.1, 2017, pp.459-465.

[48] Zupan, J., "Introduction to artificial neural network (ANN) methods: what they are and how to use them," *Acta Chimica Slovenica*, Vol.41, 1994, pp.327-327.

[49] Saritas, M. M., & Yasar, A., "Performance analysis of ANN and Naive Bayes classification algorithm for data classification," *International journal of intelligent systems and applications in engineering*, Vol.7, No.2, 2019, pp.88-91.

[50] LeCun, Y., Bengio, Y., & Hinton, G., "Deep learning," *Nature*, Vol.521, No.7553, 2015, pp.436-444.

[51] Minar, M. R., & Naher, J., "Recent advances in deep learning: An overview," *arXiv preprint arXiv:1807.08169*, 2018.

[52] Staudemeyer, R. C., & Morris, E. R., "Understanding LSTM-a tutorial into long short-term memory recurrent neural networks," *arXiv preprint arXiv:1909.09586*, 2019.

[53] Yu, J., de Antonio, A., & Villalba-Mora, E., "Deep Learning (CNN, RNN) Applications for Smart Homes: A Systematic Review," *Computers*, Vol.11, No.2, 2022.

[54] Hulsen, T., "Explainable Artificial Intelligence

(XAI): Concepts and Challenges in Healthcare," *Ai*, Vol.4, No.3, 2023, pp.652-666.

[55] Chaddad, A., Peng, J., Xu, J., & Bouridane, A., "Survey of Explainable AI Techniques in Healthcare," *Sensors (Basel)*, Vol.23, No.2, 2023.

■ 저자소개 ■



김도형
(Kim Dohyoung)

2017년 3월~현재
한림대학교 강남성심병원 신장내과
부교수
2017년 8월 중앙대학교 대학원 의학과(박사)
2007년 2월 중앙대학교 대학원 의학과(석사)
2003년 2월 중앙대학교 의학부(학사)

관심분야 : 혈액투석환자 혈관통로 연구,
복막투석환자 관리체계 개선,
EHR기반의 빅데이터, 인공지능
연구 등

E-mail : dhkim6489@hanmail.net



김현숙
(Kim Hyunsuk)

2014년 3월~현재
한림대학교 강남성심병원 신장내과
부교수
2019년 2월 서울대학교 대학원 의학과(박사)

관심분야 : 상염색체 다낭신 환자의
관리플랫폼, 만성콩팥병 환자의
보행연구, 투석환자 대상의
인공지능 연구 등

E-mail : keeee@hanmail.net



이선표
(Lee Sunpyo)

2019년 1월~현재
㈜지란지교시큐리티
지능정보사업TF장
2020년 2월 호서대학교 기술경영전문대학원
(기술경영공학박사)
1990년 2월 연세대학교 대학원 경영학과(석사)
1988년 2월 연세대학교 경영학과(학사)

관심분야 : AI, Cloud, BigData
E-mail : splee@jiran.com



오 인 종
(Oh Injong)

2021년 12월~현재
쥬지란지교시큐리티
지능정보사업TF 연구원
2021년 6월 금오공과대학교 응용수학과, 컴퓨터
공학과 복수전공(학사)
관심분야 : AI, BackEnd, BigData
E-mail : ijoh@jiran.com



박 승 범
(Park Seungbum)

2016년 3월~현재
호서대학교 기술경영전문대학원
교수
관심분야 : 빅데이터, 인공지능 등의
디지털융합 신기술을 이용한 기술
개발·실증과 기술사업화 연구 등
E-mail : parksb@hoseo.edu

논문접수일 : 2023년 12월 04일
수정접수일 : 2023년 12월 11일(1차)
2023년 12월 12일(2차)
게재확정일 : 2023년 12월 15일