

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

• 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건 을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer 🖃





의학석사 학위논문

기계학습 방법을 이용한 급성호흡곤란증후군 환자의 예후 예측 모델 개발

2020년 7월

서울대학교 대학원 의학과 중개의학 전공 김 승 빈

기계학습 방법을 이용한 급성호흡곤란증후군 환자의 예후 예측 모델 개발

지도 교수 김 희 찬

이 논문을 의학석사 학위논문으로 제출함 2020년 7월

서울대학교 대학원 의학과 중개의학 전공 김 승 빈

김승빈의 의학석사 학위논문을 인준함 2020년 7월

위 원	· 장	김 희 찬	(인)
부위·	원장	윤 형 진	(인)
위	원	박 철 기	(인)

초 록

급성호흡곤란증후군(ARDS)은 중환자실 내에서 접하는 내과적 질환 중 높은 사망률과 후유증을 보이는 질환이다. 급성호흡곤란증후군에 대해 표준 치료로는 일회호흡량을 낮게 유지하고 호기말양압(PEEP)을 높게 유지하는 등의 폐보호 환기 전략을 일반적으로 적용하고, 이를 이용하였을 때 증상이 호전되지 않을 경우 복와위 자세, 일산화질소, 전신 스테로이드 및 체외막산소공급(ECMO)까지 고려해볼 수 있다. 따라서 초기에 환자의 중증도 및 예후 예측을 정확히 하는 것이 이후의 치료 계획 결정을 도울 수 있으며, 효과적인 진료를 하는 데에 매우 중요하다 하겠다.

본 연구에서는 기계학습 알고리즘을 이용하여 환자 데이터를 분석하고 예후를 예측할 수 있는 모델을 만들었고, 이를 기존의 중증도 분석 및 예후 예측 방법과 비교하였다.

분석에 사용한 환자 데이터는 MIT에서 취합하여 인터넷 상에 공개한 MIMIC-II database이며, ICD-9에 따른 진단명을 검토하여 급성호흡곤란증후군 환자를 뽑아내었다.

급성호흡곤란증후군의 시작점은 베를린 정의에 의하였으며, 이는 PaO_2/FiO_2 비가 300 이하이면서 호기말양압(PEEP)이 5cm H_2O 이상으로 기록된 지점을 기준으로 하였다.

분석에 사용된 변수는 성별, 나이 등의 기본적인 환자 특성 및 일회호흡량, 호흡수 호기말양압 등의 인공호흡기 변수 외에도 심박수, 치온, 산소포화도 등의 활력징후 및 백혈구수, 락테이트 수치 등의 혈액 결과 수치, 신경학적인 상태, 외상이나 폐렴과 같은 선행 요인 등이다.

모델은 logistic regression, support vector machine, 그리고 gradient boosting machine 등의 기계학습 알고리즘을 이용하여 분석하였으며, 일차 결과 지표로는 병원 내에서의 사망 여부를 분석하였다. 모델의 예측도를 평가하기 위해서는 ROC(Receiver Operating Characteristic) 곡선 상의 AUC(Area Under the Curve) 값을 분석하였다.

분석 결과 기계학습을 이용한 모델은 기본의 베를린 정의 및 APACHE 점수를 이용한 예후 예측보다 우수한 예측력을 보였으며, 모델 상에서 환자의 나이와 인공호흡기 상에서의 Pleatu pressure 등이 중요한 인자로 작용하였다.

주요어: 급성호흡곤란 증후군, 기계학습, MIMIC II, 예후 예측

학 번: 2018-25904

목 차

제	1 장	서	론	1
•	제 1	절	급성호흡곤란증후군의 개요	. 1
			연구동기	
	·			
제	2 장	관	권 연구	2
			ARDS scoring.	
			기계학습 알고리즘	
	•			
제	3 장	여-	구 재료 및 방법	5
''			MIMIC-III dataset	
	" -	_	Minito III dataoo	
제	9 자	시i	험 결과	6
^ III			실험 데이터의 기본 특성	
			예측 결과 비교	
			위험인자 중요도 분석	
	/ II O	-		
궤	9 자	E	의1	Λ
^			기····································	
			열거 군식 연구 한계점1	
			한 후 연구과제	
	/II 0	己	8주 인 1 4 세	. 0
ㅊ┣·	고므치			9
Έ.	<u> ተፈ ብ</u>	. • • • •	1	. ᠘
۸ ۱	a+40.0	_		1
ΑD	strac	ι	1	.4
			표 목차	
			표 국사	
г 🛶	. 47			_
[丑	3]	• • • • •		8
			그림 목차	
[]	.림 11	 .		5
L	- p 01	••••		J

제 1 장 서 론

제 1 절 급성호흡곤란증후군의 개요

급성호흡곤란증후군(acute respiratoey distres syndrome, ARDS)은 패혈증, 외상, 약물중독 증 다양한 내과적, 외과적 질환들과 연관되어 호흡부전, 심한 동맥혈 저산소혈증, 흉부 X-선상 양측성 미만성 폐침윤을 보이는 임상 증후군을 지칭한다. 이 질환은 그간 호흡쇼크 폐(shock lung), 외상성 습윤폐(traumatic wet lung), 울혈성무기폐(congestive atelectasis), 비심인성 폐부종(noncardiogenic pulmonary edema) 등의 다양한 이름으로 불려진 바 있으며, 1994년 American—European Consensus Conference (AECC)에서 급성폐손상 및 급성호흡곤란증후군에 대한 정의를 제시하면서 명확한 기준이 제시되었다. 1,2,3 이후 해당 질환군에 대한 치료 방법이 많이 연구되면서 사망률과 후유증 발생에 있어서도 많은 개선이 있었으나, 아직도 35—65%의 높은 사망률이 보고되고 있어^{4,5}, 효과적인 치료에 대해서는 연구가 더 필요한 상황이다.

ARDS 환자의 중등도를 평가하여 생존율이나 재원기간 등 병의 경과나 예후를 예측하는 것은 치료의 방향 및 적극성의 정도 등을 결정하는 데 중요한 역할을 하며, 다양한 지표가 이를 위하여 이용되어왔다. 이 중 대표적인 것이 2011년 독일 베를린에서 진행된 회의에서 초안이 만들어진 Berlin 정의이며⁵, 현재도 임상 현장에서 이 기준에따라 중증도를 3단계로 분류하여 임상에 활용하고 있다.

제 2 절 연구동기

상기 서술한 바와 같이 ARDS 환자의 예후 평가는 치료 방향 결정에 중요하며, 보존적 치료부터 시작하여 단계적으로 기계 환기 상의 저일회호흡량 환기(low tidal volume ventilation) 및 높은호기말양압(PEEP), 폐포동원술(alveolar recruitment maneuver), 신경근육차단제(neuromuscular blocker) 투여, 복와위(prone position) 적용, 그리고 체외막산소공급(Extracorporeal membrane oxygenation, ECMO)까지 치료 강도를 올리는 데에 기준이 될 수 있다. 이와 관련하여 ARDS 환자의 예후와 Berlin 정의의 상관관계에 대한

연구에서 AUC 0.6⁶, 중환자실의 중증 지표로 널리 사용되는 APACHE II score와의 상관관계에 대한 연구의 경우 AUC 0.66⁷으로 각각계산되었던 바 있고, 그 외에도 여러 가지 임상지표가 예후 예측을 위해이용되었으나 만족스럽지 못한 예측력을 보이는 모델들이 대부분이다.이에, 근래 기계학습 알고리즘을 이용한 분석이 의료 빅데이터에활발하게 적용되고 있는 바^{10,11,12}, 기계학습의 기법으로 기계환기 변수및 환자 데이터를 분석하여 ARDS 환자의 예후를 좀 더 정확하게예측할 수 있다고 판단된다.

제 2 장 관련 연구

제 1 절 ARDS scoring

ARDS를 scoring 하는 방법으로 가장 널리 통용되는 방법은 [표 1]에 기술된 Berlin 정의이며⁵, 이에 따르면 질환의 중증도가 PaO2/FiO2 ratio를 기준으로 3 단계로 나뉘어, 수치가 높을수록 예후가 악화되는 것을 확인할 수 있다. 이를 기준으로 임상에서는 ARDS 환자의 예후 예측 및 치료 반응을 확인한다. 임상적 데이터베이스를 이용하여 Berlin 정의에 대해서 예측 타당도 분석을 시행한 결과에서도 Berlin 정의 상의 중증도에 따라 사망률이 유의하게 증가하였고 ventilator-free days는 감소하였으며, 기계환기 기간은 유의하게 증가하여, 이러한 분류방법이 ARDS 환자를 치료하고 예후를 예측하는 지표로서의 신뢰도를 얻게 되었다

[표 1] ARDS에서의 Berlin 정의

Acute respiratory Distress Syndrome			
Timing	Within 1 week of a known clinical insult or new or worsening		
	respiratory symptoms		
Chest	Bilateral opacities - not fully explained by effusions, lobar/lung		
imaging	collapse, or nodules		
Origin of	Respiratory failure not fully explained by cardiac or fluid overload		
edema	Need objective assessment (eg. Echocardiography) to exclude		
	hydrostatic edema if no risk factor present		

0	xygenation		
	Mild	200mm Hg < PaO ₂ /FiO ₂ ≤ 300mm Hg	
		with PEEP or CPAP ≥ 5cm H ₂ O	
	Moderate	100mm Hg < PaO ₂ /FiO ₂ ≤ 200mm Hg with PEEP ≥ 5cm H ₂ O	
	Severe	$PaO_2/FiO_2 \le 100$ mm Hg with PEEP ≥ 5 cm H_2O	

제 2 절 기계학습 알고리즘

기계학습이란 데이터로부터 자동 학습을 통하여 스스로 알고리즘의 성능을 높여가는 방법을 말한다. 이러한 분석 방법은 의료 데이터와 같이 많은 변수들 간의 복잡한 비선형 관계를 다루는 데에 있어 기존의고전적 통계 기법들에 비해 우수한 예측력을 보여, 최근 여러 대규모데이터베이스를 대상으로 그 활용도가 높아지고 있다. 여러 가지기계학습 알고리즘 중에서 본 연구에서 활용한 알고리즘은 Logistic regression, Support Vector Machine, Gradient Boosting Machine 등세가지이다.

2.1 Logistic regression

Logistic regression은 영국의 통계학자인 D. R. Cox가 1958년 에 제안한 확률 모델로서, 회귀 및 분류 문제에서 많이 사용하는 모델이다. Logistic regression의 목적은 종속 변수와 독립 변수간의 관계를 구체적인 함수로 나타내어 향후 예측 모델에 사용하는 것으로, 수치 값들로 구성된 피처 벡터 $X=(x_1,\,\cdots,\,x_n)$ 와 확률값으로 정의되는 종속 변수 y간의 관계가 선형적으로 정의됨을 가정하고 이러한 선형 관계를 가장 잘 표현할 수 있는 회귀 계수를 추정하는 모델이다. 다만 일반적인 선형 회귀분석과는 다르게 종속 변수가 범주형 데이터가 되며, 입력 데이터가 주어졌을 때 해당 데이터의 결과가 특정 분류로 나위기 때문에 일종의 분류 기법으로 볼 수도 있다.

2.2 Support Vector Machine

Support Vector Machin은 1995년 러시아의 통계학자인 Vapnik이

처음 제안한 분류기법으로, 인공신경망과 마찬가지로 복잡한 비선형 관계를 갖는 이분류 문제를 해결하는데 적합한 분류 기법이다. 복잡한 분류문제에서 상당히 우수한 예측 정확도를 보인다는 점은 인공신경망과 동일하나, SVM은 상대적으로 여러 측면에서 장점을 갖고 있다. 우선, SVM은 '경험적 위험 최소화(empirical risk management)'를 추구하는 인공신경망과 달리 '구조적 위험(structural risk)'을 최소화하는 방향으로 학습을 수행하도록 설계되어 있다. 때문에, SVM은 상대적으로 과적합화(overfitting) 문제에서 자유로울 수 있으며, 추정해야 할 많은 가중치들로 인해 학습 시 많은 양의 데이터를 요구하는 인공신경망과 달리, SVM은 서포트 벡터(support vector)라 불리는 소수의 데이터 만을 최종적으로 학습에 사용하기 때문에, 일반적으로 적은 양의 학습 데이터로도 우수한 예측성과를 나타낸다.

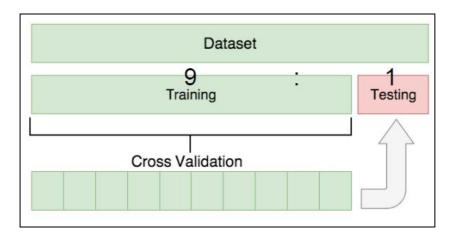
2.3 Gradient Boosting Machine

Gradient Boosting Machine(GBM)은 Friedman(2001)이 고안한 방식으로, 전통적인 의사결정트리의 약한 학습자들을 앙상블 기법으로 결합하여 예측 모델을 생성하는 기계학습 알고리즘이다. 이 모델은 다른 부스팅 방법과 같이 단계별로 모델을 생성하고 임의로 차등화 할 수 있는 손실 함수를 최적화하여 모델을 일반화한다. 기계학습에서 부스팅(boosting)은 약한 학습기(weak learner)들을 결합하여 강력한 학습기(strong learner)를 만드는 방식을 의미한다. 정확도가 낮더라도 모델을 생성하고, 생성된 모델의 오류는 다음 모델이 보완한다. 이런 과정을 거치면서 이전 모델보다 정확한 모델이 만들어지고, 이 과정을 반복하면서 정확도를 높이는 것이 기본 원리이다. 예측 모델 학습을 손실함수(loss function)을 최소화하는 파라미터를 찾는 일이이라 할 때 최적의 파라미터를 찾는 방법 중 하나가 gradient descent이다. 손실함수를 파라미터로 미분해서 기울기를 구하고, 값이 작아지는 방향으로 파라미터를 움직이다보면 손실함수가 최소화되는 지점에 도달한다. Gradient boosting은 이 탐색 과정이 함수 공간에서 이루어진다. 그래서 손실함수를 파라미터가 아니라 현재까지 학습된 모델 함수로 미분한다. 파라미터 공간에서는 계산된 기울기를 따라서 학습률(learning rate,)에 맞춰 변화량을 업데이트한다. 정리하면 gradient boosting에서는 gradient가 현재까지 학습된 모델의 약점을 드러내는 역할을 하고, 다른 모델이 그 것을 중점적으로 보완해서 성능을 boosting한다.

2.4 Hyperparameter tuning

상기 알고리즘을 이용하여 분석하는 과정에서, 학습효과의 향상 및 Validation을 위하여 다음 [그림 1]과 같은 10-fold cross validation을 시행하였다. 즉, 전체 Dataset을 임의로 10개의 군으로 나눈 뒤에, 9개의 군으로 학습을 시킨 뒤 나머지 1개의 군에서 테스트를 시행하는 방법을 사용하였다.

[그림 1] 10-fold cross validation



제 3 장 연구 재료 및 방법

제 1 절 MIMIC-III dataset9

MIMIC은 MIT에서 주관하여 취합하고 인터넷에 공개한 중환자실환자 데이터로, 2001년부터 2012년까지 Beth Israel Deaconess Medical Center의 중환자실에 머물렀던 4만 명 이상의 환자의 각종임상지표 및 검사 수치와 관련된 비식별화 대규모 데이터베이스이다. 해당 데이터베이스에는 인구통계학적정보, 진단, 치료, 처방, 실험실검사, 생체모니터링, 입원기록, 간호기록 및 이미징 보고서, 진료비 및사망률(입원 및 퇴원)이 포함되며, 특히 본 연구에서 활용되는

인공호흡기 데이터 및 혈액검사 결과 등의 수치가 자세히 기록되어 있다. 같은 방법으로 다기관에서 취합한 20만명의 중환자 데이터를 2018년에 eICU Collaborative Research Database라는 이름으로 발표한 바 있으며, 본 연구에서 이 데이터는 상기 MIMIC-III data를 이용한 모델의 테스트에 사용하였다.

제 4 장 실험 결과

제 1 절 실험 데이터의 기본 특성

본 실험에 사용된 환자 데이터의 기본 특성을 분석한 결과는 다음 [표 2]와 같다.

[표 2] 데이터 기본 특성 분석

		Survived	Expired	p값
		(N=1978)	(N=1352)	Ьях
mean a	age	61.8	72.6	< 0.000
Sex	F	847 (42.8%)	589 (43.6%)	
Joh	M	1131(57.2.6%)	763 (56.4%)	
mean weig	ght (kg)	88.3	80.8	
mean S	OFA	5.6	7.6	< 0.000
mean PF Ratio		184.5	169.0	< 0.000
mean GCS		13.8	13.2	
Pneumonia	0	1703(86.1%)	923 (68.3%)	0.664
1 neumoma	1	275(13.9%)	429 (31.7%)	0.001
Sepsis	0	1654(83.6%)	923 (68.3%)	< 0.000
Серзіз	1	324(16.4%)	429 (31.7%)	. 0.000
Congestive	0	1353(68.4%)	790 (58.4%)	
Heart	1	625 (31.6%)	562(41.6%)	

Failure				
mean Crea	atinine	1.4	1.8	
Renal	0	1732(87.6%)	1064(78.7%)	
Failure	1	246(12.4%)	298 (21.3%)	
Chronic	0	1421(71.8%)	950(70.3%)	0.344
Pulmonary	1	557 (28.2%)	402(29.7%)	0.044
mean p	O ₂	128.1	120.2	< 0.000
mean po	CO ₂	43.8	43.3	0.190
mean I	ЭН	7.4	7.4	
mean W	/BC	13.1	14.2	
mean INR		1.4	1.6	
mean HR		88.0	89.1	
mean SBP		119.2	114.0	
mean DBP		61.5	57.5	
mean MBP		79.0	75.1	< 0.000
mean Hb		11.2	10.7	
mean body temperature		37.1	36.9	
mean RR		19.3	20.4	
mean Glucose		143.0	150.6	

상기 분석 결과를 검토하여 볼 때 임상적으로 유의미한 내용들을 확인하여볼 수 있는데, 우선 다발성 장기 부전과 연관된 SOFA score 상에서 사망한 환자들의 경우 생존한 환자들과 비교하였을 때 유의미하게 점수가 높았으며, 베를린 정의 상 ARDS 환자의 위중도를 분류하는 PF ratio의 경우 작을수록 중증도가 심하다는 것을 나타내는데, 사망한 군에서의 PF ratio 수치가 유의미하게 낮은 결과를 보였다.

또한 폐렴 여부에 있어서는 생존한 환자군과 사망한 환자군간의 유의미한 차이를 확인할 수 없었으나, 패혈증의 경우 사망한 환자군에서 유의미하게 높은 수치를 보였다. 이는 상기한 SOFA score 수치 경향과도 일치하는 것으로, ARDS 환자에 있어 패혈증으로 대표되는 다발성 장기부전으로 진행할수록 사망률이 높아지는 것을 보여준다.

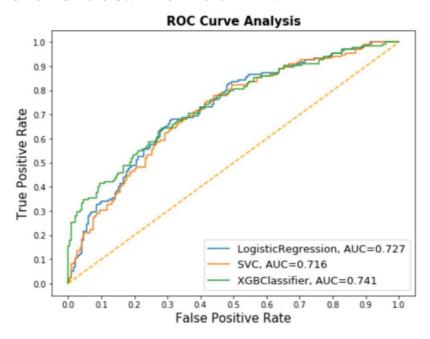
그 외에 신장의 기능을 나타내는 Creatinine 수치에 있어서 사망한 환자군에서 좀 더 나쁜 수치를 확인할 수 있었으며, 이는 신부전(renal failure)이 발생한 환자 수의 차이에도 반영되었다.

만성 폐질환의 여부와 관련하여서는 생존한 환자군과 사망한 환자군 사이에 유의미한 차이는 보이지 않았다.

제 2 절 예측 결과 비교

Logistic regression, Support vector machine, Gradient Boosting machine의 방법으로 모델링하여 예후를 예측할 경우, 환자 사망 여부를 예측하는 데에 있어 ROC curve를 그리면 다음 [그림 2]의 그래프와 같다.

[그림 2] 기계학습 분석 결과의 ROC곡선



또한, ROC curve를 이용하여 AUC를 계산하고, 이를 Berlin 정의 및 APACHE 점수를 이용한 예측 결과와 비교하면 다음과 같다.

표3. 예측 Model 별 AUC 비교

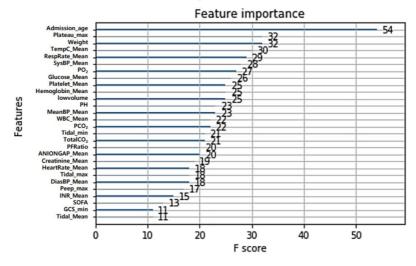
Model	AUC
Berlin definition	0.671
APACHE score	0.664
Logistic regression	0.716
SVM	0.727
Gradient Boosting Machine	0.741

제 3 절 위험인자 중요도 분석

상기 분석 중 특히 Gradient Boosting Machine의 경우 예후 결정에 미치는 중요한 인자를 뽑아낼 수 있었으며, 이는 다음 [그림 3]과 같다. 이를 보면 입원 시 나이가 환자군의 예후를 결정하는 데에 있어 제일 큰 영향을 미쳤으며, 그 다음으로는 인공호흡기의 변수 중 Pleatu pressure 등이 중요한 인자로 작용한 것으로 확인된다.

그 외에 환자의 체온, 혈압등의 순으로 환자의 예후에 미치는 영향을 미쳤으며, 기존에 ARDS 환자의 예후 연구에서 중요하게 작용하였던 인공호흡기 tidal volume은 본 연구에서는 중요하지 않은 것으로 분석되었다.

[그림 3] Gradient Boosting Machine 분석 시 위험인자의 중요도 분석



제 5 장 토 의

제 1 절 결과 분석

상기와 같이 기계학습을 이용하여 중환자실 데이터를 분석하였을 때, 기존 임상에서 흔하게 쓰는 중증도 지표와 비료한 결과보다 더 좋은 예측도를 보였으며, 이는 환자의 예후 및 치료 반응을 평가하는 데에 있어 유용하게 작용할 것으로 보인다.

또한 이 같은 분석이 실제 데이터를 얼마나 예측하는지 데스트해보기 위하여 MIT에서 제공하는 eICU Collaborative Research Database를 사용하여 모델을 적용하였으며, Gradient Boosting Macine 알고리즘을 이용하여 분석한 결과 AUC 0.692의 결과를 얻을 수 있어, 이 또한 기존 지표들(Berlin definition으로 분석한 경우 0.669, APACHE score를 이용하여 분석한 경우 0.661)보다 우수한 예측력을 보였다.

제 2 절 연구 한계점

상기 연구는 특정 의료시설의 공개된 중환자실 데이터를 바탕으로 하므로, 해당 의료기관에 한정된 결과일 수 있으며, 추후 추가적인 data를 이용한 validation이 필요하다. 또한 중요도 분석을 통하여 추출한 인자들에 대해 임상적인 의미를 부여하기 위해서는 추가적인 연구 및 분석이 필요할 것으로 생각된다.

또한 분석된 데이터들이 normalization되지 못하였다는 점이 한계점이며, 모델의 예측력을 분석함에 있어 Net reclassification improvemen 혹은 Hosmer-Lemeshow test와 같은 좀 더 신뢰성 있는 지표를 사용하지 않고 단순히 AUC만을 비교하였던 점이 한계점으로 남는다.

제 3 절 향후 연구 과제

실제 중환자실 데이터를 이용한 후향적인 validation이 요구되며, 이를 바탕으로 실시간 데이터를 활용한 예후 예측이나 현재 시행중인 처치에 대한 반응 여부를 평가할 수 있다면 개인 맞춤 치료가 가능할 것이다. 또한 이를 바탕으로 중환자의 예후 개선에 큰 도움이 될 것이라 기대한다.

또한 상기 분석은 시간에 따른 환자 상태 변화를 반영하지 못하여서, 상태 악화 혹은 호전 정도를 반영할 수 있는 모델을 만들었을 때 임상적으로 예후를 예측하고 치료방법을 수립하는 데에 더 도움이 될 수 있을 것으로 생각된다.

참고 문헌

- 1. Ashbaugh DG, Bigelow DB, Petty TL, Levine BE. Acute respiratory distress in adults. Lancet 1867; 2:319-323
- 2. Petty TL, Ashbaugh DG. The adult respiratory distress syndrome; clinical features, factors influencing prognosis and principles of management. Chest 1971; 60:233-239
- 3. Bernard GR, Artigas A, Brigham KL, Carlet J, Falke K, Hudson L, Lamy M, Legall JR, Morris A, Spragg R. The American-European Consensus Conference on ARDS: definitions, mechanisms, relevant outcomes, ad clinical trial coordination. Am J Respir Crit Care Med 1994; 149:818-824
- 4. Rubenfeld GD, Caldwell E, Peabody E, Weaver J, Martin DP, Neff M, et al. Incidence and outcomes of acute lung injury. N Engl J Med. 2005; 353: 1685–1693.
- 5. Rezoagli E, Fumagalli R, Bellani G. Definition and epidemiology of acute respiratory distress syndrome. Ann Transl Med. 2017; 5: 282.
- 6. Pisani L, Roozeman J-P, Simonis FD, Giangregorio A, van der Hoeven SM, Schouten LR, et al. Risk stratification using SpO2/FiO2 and PEEP at initial ARDS diagnosis and after 24 h in patients with moderate or severe ARDS. Ann Intensive Care. 2017; 7: 108
- 7. Jesús Villar et. Al., Age, PaO2/FIO2, and Plateau Pressure Score: A Proposal for a Simple Outcome Score in Patients With the ARD Crit Care Med 2016;44:1361-9
- 8. Brown SM, Grissom CK, Moss M, Rice TW, Schoenfeld D, Hou PC, et al. Nonlinear Imputation of Pao2/Fio2 From Spo2/Fio2 Among Patients With Acute Respiratory Distress Syndrome. Chest. 2016; 150: 307–313.
- 9. Johnson AEW, Pollard TJ, Shen L, Lehman LH, Feng M, Ghassemi M, et al. MIMIC-III, a freely accessible critical care database. Sci Data. 2016; 3: 160035
- 10. Battiti R. Using Mutual Information for Selecting Features in Supervised Neural Net Learning. Neural Netw IEEE Trans On. 1994; 5: 537–550.
- 11. Alonso-Atienza F, Morgado E, Ferna'ndez-Martı'nez L,

Garcı'a-Alberola A, Rojo-A' lvarez JL. Detection of Life-Threatening Arrhythmias Using Feature Selection and Support Vector Machines. IEEE Trans Biomed Eng. 2014; 61: 832-840.

12. Yang P, Wu T, Yu M, Chen F, Wang C, Yuan J, et al. A new method for identifying the acute respiratory distress syndrome disease based on noninvasive physiological parameters. PLoS ONE 2020 15(2): e0226962.

Abstract

Machine learning-based model for prediction of outcomes in Acute Respiratory Distress Syndrome

Kim Seung Bin Translational Medicine, College of Medicine Seoul National University

The acute respiratory distress syndrome (ARDS) is a significant cause of morbidity and mortality in intensive care unit (ICU). Standard management of ARDS includes several lung protective strategies (low tidal volume and high PEEP setting), but these managements are not effective for every ARDS patients. Those not—responders for lung protective ventilation must be treated with other management (prone position, alveolar recruitment, steroid, or even ECMO), so rapid decision of responsiveness of initial treatment is critical for the prognosis of patient.

Aim of this study is analyzing clinical data by machine learning algorithm and making a model that can predict the mortality of the patient.

Clinical data of adult patients (age≥18 years) were extracted from the MIMIC- III database and Philips eICU database. We use ICD-9 diagnosis codes and procedure codes identifying mechanically ventilated patients are the basis for identifying ARDS patients.

Time points of ARDS onset were defined based on Berlin criteria, i.e. PaO2/FiO2 ratio ≤ 300 with PEEP at least 5cm H2O.

Ventilator parameters (set tidal volume, observed tidal volume) has been used. Sex, Age, Vital sign (heart rate, respiratory rate, body temperature, mean arterial pressure, oxygen saturation, tidal

volume), laboratory test (white blood cell counts, hemoglobin,

lactate, creatinine, bicarbonate, pH), has been extracted and

categorized. Neurologic status (GCS) and predisposition factor

(trauma, pneumonia, etc.) has been also extracted from EMR. Other

features can be extracted or engineered.

Models was developed using machine learning algorithms - logistic

regression, support vector machine, and gradient boosting machine.

The primary outcome was in-hospital mortality, and morbidity in

ICU also analyzed. And the quality of the model's prediction was

estimated by AUC(Area Under the Curve) of the ROC(Receiver

Operating Characteristic) curve.

As a result, the models built by machine learning algorithms showed

batter prediction than classic scores (Berlin definition and APACHE

score)

Keywords: ARDS, Machine Learning, MIMIC II, Prediction, Prognosis

Student Number: 2018-25904

15