

논문 2011-48SC-2-8

출혈성 쇼크를 일으킨 흰쥐에서 인공신경망과 지원벡터기계를 이용한 생존율 비교

(Comparison of Survival Prediction of Rats with Hemorrhagic Shocks Using Artificial Neural Network and Support Vector Machine)

장 경 환*, 유 태 근**, 남 기 창***, 최 재 림*, 권 민 경****, 김 덕 원*****

(Kyung Hwan Jang, Tae Keun Yoo, Ki Chang Nam, Jae Rim Choi, Min Kyung Kwon, and Deok Won Kim)

요 약

진 세계적으로 상해로 인한 사망자 중 1/3의 직접적인 사망 원인은 출혈성 쇼크이다. 그러나 초기 쇼크에서 이를 정확히 예측할 수 있다면 신속한 치료가 가능하여 그 피해를 줄일 수 있다. 본 논문의 목적은 흰쥐의 대퇴부정맥을 통해 일정량의 출혈을 시키면서 변화하는 생리적 변수인 심박수, 수축기 혈압, 평균 동맥압, 호흡수, 체온 데이터로 최적의 생존 예측 모델을 제시하여 출혈성 쇼크를 조기 진단하는 것이다. 예측 모델로는 최근 많이 연구되는 인공신경망과 지원벡터기계 방법을 사용하였다. 과대적합을 피하고 최적의 모델을 선정하기 위해 10-fold cross validation을 수행하였을 때, 인공신경망의 경우 은닉노드 수가 3개인 모델이 가장 우수한 성능을 보였고, 지원벡터기계에서는 가우시안 커널함수를 이용한 모델이 가장 우수한 성능을 보였다. 평가 데이터 세트를 이용하여 각각의 생존 예측 모델을 평가한 결과 인공신경망의 경우 민감도 88.9 %, 특이도 96.7 %와 정확도 92.0 %를 보였고, 지원벡터기계의 경우 민감도 97.8 %, 특이도 95.0 %와 정확도 96.7 %를 보였다. 따라서 출혈에 따른 흰쥐의 생존 예측에서 지원벡터기계가 인공신경망보다 더 우수한 성능을 보이는 것을 확인하였다.

Abstract

Hemorrhagic shock is a cause of one third of death resulting from injury in the world. Early diagnosis of hemorrhagic shock makes it possible for physician to treat successfully. The objective of this paper was to select an optimal classifier model using physiological signals from rats measured during hemorrhagic experiment. This data set was used to train and predict survival rate using artificial neural network (ANN) and support vector machine (SVM). To avoid over-fitting, we chose the best classifier according to performance measured by a 10-fold cross validation method. As a result, we selected ANN having three hidden nodes with one hidden layer and SVM with Gaussian kernel function as trained prediction model, and the ANN showed 88.9 % of sensitivity, 96.7 % of specificity, 92.0 % of accuracy and the SVM provided 97.8 % of sensitivity, 95.0 % of specificity, 96.7 % of accuracy. Therefore, SVM was better than ANN for survival prediction.

Keywords : hemorrhagic shock, artificial neural network, support vector machine, rats, survival prediction

* 학생회원, 연세대학교 생체공학협동과정(Graduate Program in Biomedical Engineering, Yonsei University)

** 학생회원, 연세대학교 의학전문대학원 (Yonsei University College of Medicine)

*** 평생회원, 세브란스병원 의료기기 임상시험 센터

(Clinical Trials Center for Medical Devices, Severance Hospital)

**** 학생회원, 연세대학교 의과학과(Brain Korea 21 Project for Medical Science, Yonsei University)

***** 평생회원, 연세대학교 의과대학 의공학교실

(Dept. of Medical Engineering, Yonsei University College of Medicine)

※ 이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2009-0083613).

접수일자: 2010년10월22일, 수정완료일: 2011년3월10일

I. 서 론

2010년 세계보건기구(World Health Organization, WHO)의 보고에 따르면 전 세계적으로 상해(injury)로 인한 사망은 전체 사망의 14 %를 차지하며, 그 중 1/3의 직접적인 사망 원인은 출혈로 인한 저혈량성 쇼크다^[1-2]. 우리나라의 경우도 최근 8년 동안 응급실에서 다발성 손상으로 사망한 환자들 중 74 %의 원인이 저혈량성 쇼크로 판명됐다^[3-4]. 쇼크란 조직에 공급되는 산소의 부족으로 인해 대사에 이상이 생기는 임상증후군을 말한다^[5, 6]. 쇼크가 진행된 상태에서는 심박수, 혈압, 체온 변화 등의 임상적 징후가 뚜렷하여 진단의 어려움은 없으나 이미 주요 장기가 손상되어 치료에 대한 예후가 좋지 않다. 반면에 초기 쇼크 상태의 경우 뚜렷한 임상 증상이 없어 진단과 치료가 지연될 수 있다. 따라서 출혈성 쇼크의 조기 진단이 매우 중요하므로 이를 위한 다양한 시도가 이루어지고 있다. 그 예로 다양한 혈액학적 지표와 혈액검사를 통하여 쇼크 환자의 상태와 예후를 판단하려는 연구가 계속 되었으며^[7-10], 최근 통계적 방법^[11]과 기계학습 방법^[12]들을 이용한 시도가 늘어나고 있다.

다양한 생체 신호들을 이용하여 객관적으로 검증된 우수한 성능의 생존 예측 모델을 제시한다면, 실제 임상에서의 적용이 가능해질 수 있을 것이다. 그러나 기존의 연구들이 훈련을 통하여 많은 생존 예측 모델을 제시하였음에도 불구하고 생체 신호 데이터들 간의 주요 상호작용과 비선형성 때문에 만족할만한 성능을 보이지 못하였다^[13, 14, 15]. 또한 검증과정 없이 분류기 모델을 선정하였으므로 생존 예측 모델이 일반화 되었다고 볼 수 없다^[16]. 따라서 본 연구에서는 흰쥐의 대퇴부정맥을 통해 일정량의 출혈을 유도하면서 획득한 심박수(heart rate, HR), 수축기 혈압(systolic blood pressure, SBP), 평균 동맥압(mean blood pressure, MBP), 호흡수(respiration rate, RR) 및 체온(temperature, TEMP)의 생체 신호를 이용하여 출혈로 인한 쇼크 발생 시 생존을 예측할 수 있는 생존 예측 모델을 생성 및 검증하고 그 성능을 객관적으로 비교하여 최적의 생존 예측 모델을 제안하였다. 예측 모델로는 최근 많이 연구되고 있는 훈련 및 분류 방법인 인공신경망(artificial neural network, ANN)과 지원벡터기계(support vector machine, SVM)를 사용하였다.

각각의 분류 방법들을 이용하여 생존 예측 모델을 선

정할 때 10-fold cross validation을 사용하여 객관적으로 가장 우수하고 일반적인 생존 예측 모델을 선정하였다. 이와 같은 방법을 이용하여 인공신경망과 지원벡터기계에서 선정한 각 모델들에서의 생존 예측 결과를 비교해 보았다.

II. 방 법

1. 데이터 획득^[16]

수컷 흰쥐(Sprague-Dawley rats) 45마리를 사용하여 출혈량에 따라 각각 15 마리씩 3 군으로 나누었다. 이때 출혈량의 기준은 체중 100 g당 2.0 ml, 2.5 ml, 3.0 ml로 전체 혈액 중 각각 32.8 %, 41.0 %, 49.2 %의 출혈에 해당되는 양이다. 이는 임상에서 출혈성 쇼크의 단계인 Class III(전체 출혈량의 30-40 %)과 Class IV(전체 출혈량의 40 % 초과)에 해당된다^[17]. 출혈을 일으킨 흰쥐로부터 측정된 심박수, 수축기 혈압, 평균 동맥압, 호흡수 및 체온 데이터는 그림 1과 같이 출혈 종료 시점인 30 분을 기준으로 출혈 종료 전과 후 5 분, 총 10 분의 구간에 대하여 1 분간 평균값을 구하였다. 따라서 한 개체 당 10분의 데이터 획득 구간에서 10개의 데이터 세트가 만들어져 총 450개의 데이터 세트가 만들어 졌다. 생존 데이터 세트(survival set)와 사망 데이터 세트(death set)를 실험 시작 후 150 분을 기준으로 나누었을 때 450개의 데이터 세트 중 190개는 생존한 데이터 세트이며 260개는 사망한 데이터 세트이다. 각각의 데이터 세트는 위의 다섯 가지 측정 변수 값과 생존 여부에 관한 정보를 갖고 있는 하나의 독립적인 데이터 세트로 생존 예측 모델 형성을 위한 훈련과 모델 검정을 위한 평가에 사용하였다.




그림 1. 흰쥐의 출혈성 쇼크 실험 프로토콜^[16]

Fig. 1. Experimental protocol for rats with hemorrhagic shock^[16].

2. 생존 예측 모델

흰쥐로부터 획득한 450개의 생체 신호 데이터 세트

표 1. 전체 데이터의 생존 여부와 훈련 및 평가 데이터 세트 분포

Table 1. Distribution of all data divided into training set and test set, survival set and death set.

Group	Training set	Test set	Total set
Survival set	130	60	190
Death set	170	90	260
Total set	300	150	450

를 중복을 피하여 무작위로 표 1과 같이 300개의 훈련 데이터 세트(training set)와 150개의 평가 데이터 세트(test set)로 나누었다. 이때 300개의 훈련 데이터 세트는 10-fold cross validation을 위해 사용되며 이를 바탕으로 생존 예측 모델의 훈련 및 검증이 이루어진다. 또한 평가 데이터 세트를 적용하여 제시한 생존 예측 모델을 평가하고 그 결과는 인공신경망과 지원벡터기계의 성능을 비교하는데 사용되었다.

다양한 개체로부터 얻은 생체 신호 데이터의 경우 각각의 범위가 다르므로 이에 대한 영향을 받지 않고 생존 예측 모델을 효과적으로 학습시키기 위하여 실험에서 얻은 데이터 세트 $X^k = (x_1^k, x_2^k, \dots, x_i^k)$ 를 식 (1)을 이용하여 입력 변수를 0에서 1사이의 값으로 스케일링(scaling) 하였다.

$$X_{scaling}^k = \left(\frac{x_1^k - \min_1}{\max_1 - \min_1}, \dots, \frac{x_i^k - \min_i}{\max_i - \min_i} \right) \tag{1}$$

입력 변수로 사용되는 데이터 세트는 심박수, 수축기 혈압, 평균 동맥압, 호흡수 및 체온으로 이루어져있으므로 i 값은 5가 된다. \min_i 과 \max_i 는 각 생체 신호 데이터의 최소값과 최대값을 의미한다. 생성된 생존 예측 모델을 평가할 경우에도 입력 데이터 세트는 같은 \min_i 과 \max_i 를 이용하여 똑같이 스케일링 해주어야 한다. 인공신경망과 지원벡터기계의 분석을 위해 MATLAB Version 7.6 (Mathworks Inc, Natick, USA)을 사용하였다.

가. 인공신경망

인공신경망은 인간의 뇌신경망의 구조를 모방하여 문제 해결에 적용하고자 하는 기법으로, 본 연구에서의 인공신경망 구조는 일반적으로 사용하고 있는 다층 퍼셉트론(multi-layer perceptron)을 적용하였다. 그림 2의

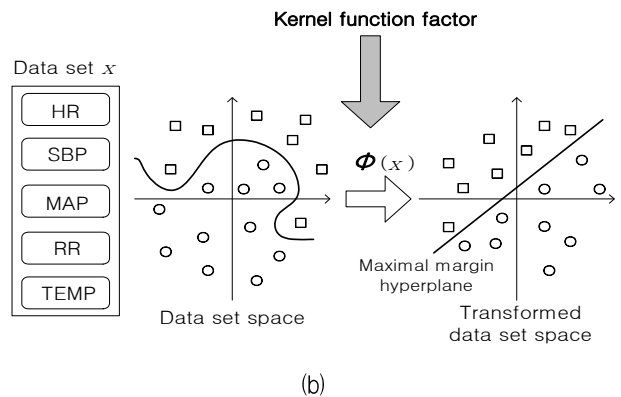



그림 2. 예측 모델과 변수에 대한 도식
 (a) 인공신경망의 은닉 노드와 가중치 변수
 (b) 지원벡터기계의 커널함수 변수
 HR: 심박수, SBP: 수축기 혈압, MBP: 평균 동맥압, RR: 호흡수, TEMP: 체온

Fig. 2. Features about prediction models and their variables.

(a) weight and hidden nodes factor of ANN.

(b) kernel function factor of SVM.

HR: heart rate, SBP: systolic blood pressure, MBP: mean blood pressure, RR: respiration rate, TEMP: temperature.

(a)는 적용된 인공신경망이 각각 한 개의 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성된 것을 보여준다. 훈련 방법은 빠른 속도로 국소 최적해를 찾는 Levenberg - Marquardt 역전파(back-propagation) 방법을 사용하였다. 인공신경망의 구조 설계 시 은닉층 내 은닉 노드의 수의 결정은 출력값에 큰 영향을 준다^[18]. 따라서 은닉 노드의 수는 최적의 인공신경망 모델을 결정하는데 매우 중요하다. 일반적으로 은닉 노드의 수를 결정하는 방법은 시행오차를 통한 경험적 방법으로 결정되지만, 최근에는 은닉노드의 수를 입력 노드와 출력노드 사이의 수, 입력 노드와 출력노

표 2. 인공신경망과 지원벡터기계의 구조 및 훈련 변수 설정

Table 2. Set-up variables of ANN and SVM for architecture and training.

(a)		(b)	
ANN Architecture	variable	SVM Architecture	variable
input nodes	5	order of polynomial	4
output nodes	1	sigma of Gaussian radial basis	1
hidden layers	1	Optimization method	quadratic programming
hidden nodes	2-10	maximum iteration	10000
training epoch	500		
error goal	0		

드의 합에 2/3를 곱한 수, 입력노드의 두 배 이하의 수로도 제시하고 있다^[18]. 따라서 본 연구에서는 은닉노드의 수를 2-10개로 변경해가며 최적의 은닉노드의 수를 찾고 이를 제안하였다. 인공신경망은 훈련시킨 데이터에 최적화 되도록 분류 모델을 형성한다^[19]. 그러나 이러한 인공신경망의 특징이 모델의 과대적합(overfitting)을 가져와 일반화된 분류 모델이 생성되지 않을 수 있으므로 적절한 인공신경망의 구조 설계가 중요하다^[20]. 표 2 (a)는 본 연구에 설계된 인공신경망의 구조이다.

나. 지원벡터기계

지원벡터기계는 여러 통계적 분류 방법과, 인공신경망의 대안적인 훈련 방법으로, 데이터 패턴을 고차원의 특징 공간으로 사상(mapping)시켜 지원 벡터(support vector)라 불리는 훈련 데이터로 분류 경계를 표현하는 것이다. 이는 분류 경계를 이루는 초평면(hyper-plane)과 지원 벡터와의 거리가 최대가 되도록 하는 훈련 과정을 거쳐 최적의 분류 모델을 생성한다. 그림 2의 (b)와 같이 일반적으로 지원벡터기계의 전처리 단계에서 커널함수(kernel function)를 이용하여 고차원의 공간으로 사상시키면 선형 분리가 가능한 조건이 된다. 따라서 이 변환함수와 분리 평면이 모델의 정확도(accuracy)를 가장 높이도록 최적화 시키는 것이 지원벡터기계의 목표이다. 본 연구에서는 커널함수를 쓰지 않은 지원벡터기계와 커널 함수를 각각 2차(quadratic), 4차(polynomial), 가우시안(Gaussian radial basis) 함수들로 구성된 생존 예측 모델을 제안하였다. 표 2 (b)는

실험에 설계된 지원벡터기계 모델의 구조이다.

다. 10-fold cross validation 및 최적 모델 선정

인공신경망과 지원벡터기계에 의해 제시된 모델이 과대적합을 피하고 최적의 생존 예측 모델을 선정하기 위해 10-fold cross validation을 사용하였다. 이 방법은 제한된 수의 데이터 세트를 사용하는 경우, 예측 모델을 검증하는 가장 대표적인 방법이다. 10-fold cross validation의 과정은 훈련 데이터 세트와 평가 데이터 세트의 중복을 피하여 무작위로 나눈 후, 훈련 데이터 세트를 중복되지 않도록 10등분 한다. 10개로 등분된 집단들 중 하나의 집단을 검증 데이터 세트(validation set)로, 나머지 9개의 집단을 검증을 위한 훈련 데이터 세트로 사용하여 생존 예측 모델을 만들고 분류 성공률, 즉 정확도를 확인한다^[21]. 나머지 집단들이 모두 검증 데이터 세트로 선택될 수 있도록 위의 과정을 10회 반복하여 생성된 10개의 분류기 모델의 정확도를 평균한다. 이 정확도의 평균값은 분류기의 성능을 나타내는 객관적인 지표라 할 수 있다.

생성된 10개의 생존 예측 모델의 정확도와 전체의 평균 정확도를 비교하여 평균 정확도에 가장 근접한 모델을 선택한다. 선택된 생존 예측 모델은 10개의 생존 예측 모델을 대표하는 모델이라 할 수 있다. 그러나 10-fold cross validation 수행 시 검증 데이터 세트의 수가 많지 않아 생존 예측 모델의 성능으로 설정한 정확도의 평균값이 일치 혹은 근접하는 모델이 다수 존재할 수 있다. 이 때, 민감도(sensitivity)와 특이도(specificity)를 기준으로 사용할 수 있는데 이들의 정의와 정확도와와의 관계는 다음 식 (2), (3), (4)와 같다.

$$\text{sensitivity} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{specificity} = \frac{TN}{TN + FP} \quad (3)$$

$$\text{accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

TP (true positive)는 진양성으로 사망한 개체를 사망군으로 올바르게 예측한 사례의 수, TN (true negative)은 진음성으로 생존한 개체를 생존군으로 올바르게 예측한 사례의 수, FP (false positive)는 위양성으로 생존한 개체를 사망군으로 예측한 사례의 수, FN




그림 3. 10-fold cross validation을 통한 생존 예측 모델 선정 흐름도
 Fig. 3. Diagram of selection for survival prediction model by 10-fold cross validation.

(false negative)는 위음성으로 사망한 개체를 생존군으로 잘못 예측한 사례의 수를 말한다. 본 연구의 궁극적인 목적은 생존 예측을 통해 생존하지 못할 것으로 분류된 환자들에게 빠른 치료를 받게 하는데 있다. 따라서 동일한 정확도를 가진 모델이 존재한다면 민감도가 더 좋은 모델을 선택했다. 이는 이 생존 예측 모델을 사용했을 경우 치료에 제외되어 사망하는 환자를 최소화하려 함이다. 이와 같이 10-fold cross validation은 정확도뿐만 아니라 민감도를 함께 고려하여 생존 예측 모델을 대표할 수 있는 최적의 모델을 결정할 수 있다.

그림 3은 10-fold cross validation을 간략히 도식화한 것으로 출혈을 일으킨 흰쥐로부터 얻은 데이터 세트 450개를 중복되지 않도록 무작위로 300개의 훈련 데이터 세트와 150개의 평가 데이터 세트로 나누었다. 이

중 300개의 훈련 데이터 세트로 10-fold cross validation을 시행하여 최적의 인공신경망과 지원벡터기계의 생존 예측 모델을 선택한다. 선택된 각각의 모델을 평가 및 비교하기 위해 훈련 후 남은 평가 데이터 세트를 인공신경망과 지원벡터기계 모델에 적용하여 민감도, 특이도와 정확도를 확인하였다. 인공신경망은 훈련을 시작할 때 무작위로 초기 가중치 값을 설정하기 때문에, 매번 훈련을 수행할 때 마다 다른 신경망 모델이 생성되어 민감도, 특이도와 정확도의 값이 다르게 나타나게 된다. 따라서 생존 예측 모델의 성능 평가에 어려움이 있을 수 있는데, 본 연구에서는 이와 같은 단점을 보완하고자 인공신경망과 지원벡터기계의 모델 생성 과정을 10회 반복하여 구한 평균 민감도, 특이도와 정확도를 바탕으로 최적의 생존 예측 모델을 제안하였다. 검증을 위한 훈련 데이터의 수가 크지 않아 무작위로 선택하는 과정을 거쳐 편향된 데이터 조합이 생길 수 있으므로, 이런 반복 검증을 통해 더욱 객관적으로 성능을 평가 할 수 있었다.

III. 실험 및 결과

생존군의 경우 출혈이 중지된 이후 심박수, 수축기 혈압, 평균 동맥압, 호흡수, 체온이 회복되나, 사망군은 회복되지 못하고 그대로 사망에 이르게 된다. 결과 데이터를 보면 생존군은 사망군에 비해 출혈 시 심박수가 느리며, 혈압은 더 높고, 체온과 호흡수는 더 높은 특징을 보여준다^[16]. 그러나 데이터에 따라 그 차이가 뚜렷하지 않고 개체마다 차이가 있기 때문에 단일 생리 변

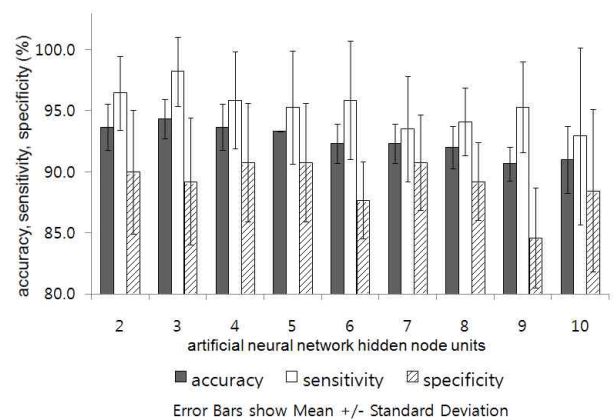


그림 4. 은닉 노드 2-10개 인공신경망의 정확도, 민감도, 특이도
 Fig. 4. Accuracy, sensitivity, and specificity hidden nodes between 2 and 10 of the ANNs.

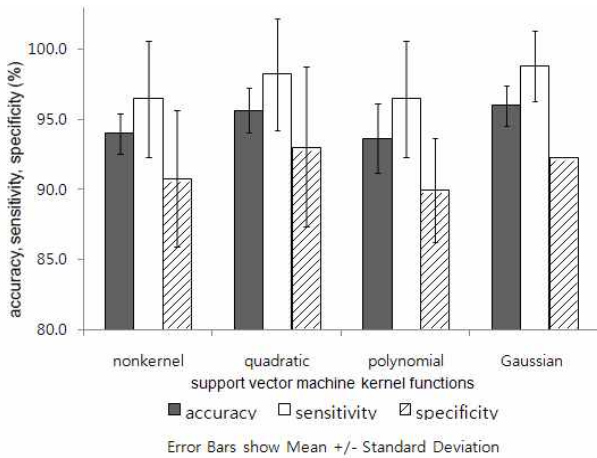


그림 5. 커널 함수를 사용하지 않은 경우와 커널함수로서 이차, 사차, 가우시안 함수를 사용한 지원벡터기계의 정확도, 민감도, 특이도

Fig. 5. Accuracy, sensitivity and specificity of SVM with no kernel function, quadratic, 4th order polynomial and Gaussian radial basis function.

수만으로는 생존군과 사망군을 분류할 수 없었다.

그림 4와 그림 5는 10-fold cross validation의 과정을 거친 인공신경망과 지원벡터기계 모델의 생성 과정을 10회 반복하여 얻은 평균 정확도, 민감도와 특이도를 그래프로 나타낸 것으로 인공신경망의 경우 은닉 노드의 수 3개를 갖는 구조의 모델에서 민감도 98.2 %, 특이도 89.2 %와 정확도 94.3 %로 가장 좋은 결과를 나타내는 것을 확인할 수 있다. 큰 추세로 볼 때 은닉 노드의 숫자가 늘어날수록 정확도가 감소하는 것을 확인할 수 있었다. 또한 지원벡터기계의 경우 커널함수의 종류가 가우시안 함수인 구조의 모델에서 민감도 98.8 %, 특이도 92.3 %와 정확도 96.0 %로 가장 좋은 결과를 나타내는 것을 확인할 수 있었다. 인공신경망 모델이 지원벡터기계 모델보다 표준 편차가 상당히 크게 나타남을 보였는데, 이는 지원벡터기계는 전역 최소값에 수렴하여 훈련 최적화를 하는데 반해 인공신경망은 지역 최소값에 수렴하여 지역적으로 과대적합하기 때문으로 사료된다.

표 3. 선정된 인공신경망과 지원벡터기계를 사용하여 평가 데이터 세트를 생존 예측한 결과
Table 3. Survival prediction results for the test sets using the selected ANN and SVM.

Model	ROC-AUC	Boundary value	Sensitivity (%)	Specificity (%)	Accuracy (%)
ANN 3 hidden nodes	0.983	0.256	88.9	96.7	92.0
SVM Gaussian radial basis	0.991	-	97.8	95.0	96.7

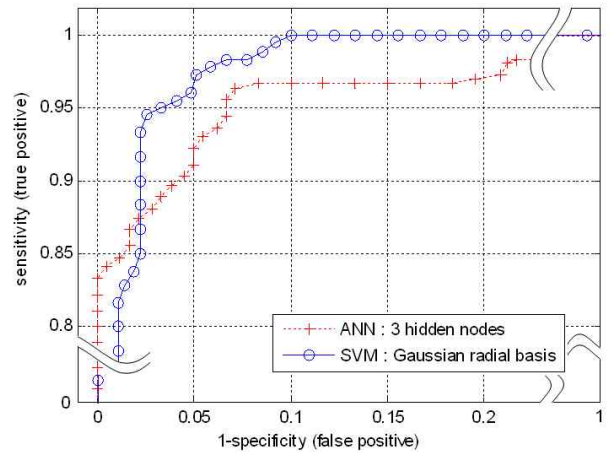


그림 6. 선정된 인공신경망과 지원벡터기계의 ROC 곡선

Fig. 6. ROC curves of the selected ANN and SVM.

표 3은 인공신경망과 지원벡터기계의 10-fold cross validation 과정을 10회 반복하여 결정된 각 분류 모델의 정확도, 민감도를 대표할 수 있는 모델을 선택하여 평가 데이터 세트로 예측한 결과이다. 인공신경망의 경우 생존군과 사망군을 나누는 경계값을 10-fold cross validation 시 결정되었던 값인 0.256로 적용하였을 때 민감도 88.9 %, 특이도 96.7 %와 정확도 92.0 %를 보였고, 지원벡터기계의 경우 민감도 97.8 %, 특이도 95.0 %, 정확도 96.7 %를 보였다.

ROC (receiver operating characteristic) 곡선은 다른 분류기들 사이의 상대적 성능을 비교하는데 유용한 방법으로^[6], 그림 6은 인공신경망과 지원벡터기계의 상대적 성능을 비교하기 위하여 나타낸 ROC 곡선이다. 은닉 노드의 수가 3개인 인공신경망 모델과 가우시안 커널함수의 구조를 지닌 지원벡터기계 모델의 ROC 곡선하의 면적(AUC: area under curve)은 각각 0.983와 0.991로 큰 차이가 없었다. 그러나 지원벡터기계의 모델이 인공신경망의 모델보다 정확도와 민감도에서 더 우수한 성능을 가지는 것을 확인할 수 있었다.

IV. 결 론

본 연구에서는 출혈을 일으킨 흰쥐를 대상으로 출혈 종료 전후 5 분간 얻은 심박수, 수축기 혈압, 평균 동맥압, 호흡수 및 체온의 생체 신호를 생존 예측 모델을 훈련하기 위한 데이터로 사용하였으며, 인공지능망과 지원벡터기계를 이용하여 최적의 생존 예측 모델을 제시하였다. 그 결과 생존군의 경우 심박수, 수축기 혈압, 평균 동맥압, 호흡수, 체온이 회복함을 보였으나, 사망군은 생존군에 비해 심박수는 느려지고, 혈압, 체온과 호흡수는 더 높은 특징을 보였다. 이와 같이 출혈성 쇼크 시 나타나는 생체 신호의 변화로 인해 정확도뿐만 아니라 민감도 함께 고려하여 우수한 예측 성능을 가진 인공지능망과 지원벡터기계를 선정할 수 있었다. 선정된 모델을 평가 데이터 세트에 적용하여 나타난 결과를 통해 지원벡터기계 모델이 인공지능망의 모델보다 우수한 정확도와 민감도를 보여 더 정확한 출혈성 쇼크의 진단이 가능할 것이라 생각된다. 그러나 데이터의 특성과 입력된 변수에 따라 생존 예측을 위한 최적의 훈련 및 분류 방법이 달라지므로 이를 고려한 적절한 분류 방법의 선택이 필요할 것이다. 또한 지원벡터기계 모델의 성능이 매우 우수함에도 불구하고 동물을 대상으로 획득한 데이터를 이용하여 생성한 생존 예측 모델은 임상에서의 예와 차이가 존재할 수 있으며, 연구에 사용된 동물 실험 결과는 출혈량을 일정하게 제어하였기 때문에 실제 임상에 적용하기에는 무리가 있다. 따라서 추후 연구로는 비제어 출혈(uncontrolled hemorrhage shock) 모델을 통해 얻은 동물 실험 결과로 다양한 출혈 실험 데이터를 확보하여 더 좋은 성능의 생존 예측 모델을 제안해야 할 것이다.

추후 연구를 통해 출혈성 쇼크를 조기 진단하여 우수한 성능으로 환자의 정확한 상태를 예측할 경우 다수의 외상 환자 발생 시 신속히 쇼크의 경중을 판단하여 사망 위험군 환자들을 우선적으로 치료할 수 있을 것이다.

참 고 문 헌

- [1] World Health Organization, World health statistics 2010, *World Health Organization Press*, pp. 62-70, 2010.
- [2] CJ Murray and AD Lopez, "Alternative projections of mortality and disability by cause 1990-2020: Global Burden of Disease Study," *The Lancet*, Vol. 349, no. 9064, pp.1498-1504, May. 1997.
- [3] CD Deakin and IR Hicks, "AB or ABC: pre-hospital fluid management in major trauma," *Journal of Accident and Emergency Medicine*, Vol. 11, no. 3, pp. 154-157, Mar. 1994.
- [4] I. B. Chang, "Analysis of causes of death of the patients with multiple traumas who died in emergent department," *Annu. Meet Korea Neurosurg Soc*, Seoul, Korea, Nov. 2007
- [5] J. Markovchick and T. Pons, *Emergency medicine secrets, 4th edition*, Philadelphia, pp. 28-32, 2006.
- [6] Martel MJ, MacKinnon KJ, Arsenault MY, Bartellas E, Klein MC, Lane CA, Sprague AE, and Wilson AK, "Hemorrhagic shock," *Journal of Obstetrics and Gynaecology Canada*, Vol. 24, no. 6, pp. 504-511, Jun. 2002.
- [7] M. Wilson, DP. Davis and R. Coimbra, "Diagnosis and monitoring of hemorrhagic shock during the initial resuscitation of multiple trauma patients: a review," *Journal of Emergency Medicine*, Vol. 24, no. 4, pp. 413-422, May. 2003.
- [8] J. H. Lee, T. K. Lee, S. W. Chung, H. W. No and D. W. Kim, "Changes in heart rate and heart rate variability induced by hemorrhagic shock in rats shock," *Shock*, Vol. 31, Suppl 1, pp. 21, Jun. 2009.
- [9] D. W. Kim, J. L. Choi and Y. S. Park, "Survival prediction in rats with fixed-volume hemorrhage using a logistic regression equation," *Shock*, Vol. 33, Suppl 1, pp. 14, Jun. 2010.
- [10] J. L. Choi, D. W. Kim and Y. S. Park, "Prediction of blood loss in rats during fixed volume hemorrhage using a regression model," *Shock*, Vol. 33, Suppl 1, pp. 14, Jun. 2010.
- [11] X. Li and F. Porikli, "Human state classification and Prediction for Critical Monitoring by real-time bio-signal Analysis," *International Conference on Pattern Recognition*, Istanbul, Turkey, Aug. 2010.
- [12] S. Y. Ji, W. Chen, K. Ward, C. Rickards, K. Ryan, V. Convertino and K. Najarian, "Wavelet based analysis of physiological signals for prediction of severity of hemorrhagic shock," *International Conference on Complex Medical Engineering*, pp. 1-6, Tempe, USA, April. 2009.
- [13] B. Eftekhari, K. Mohammad, HE. Ardebili, M. Ghodsi and E. Ketabchi, "Comparison of artificial

- neural network and logistic regression models for prediction of mortality in head trauma based on initial clinical data," *BMC Medical Informatics and Decision Making*, Vol. 5, no. 3, pp. 1-8, Feb. 2005.
- [14] SM. Dirusso, T. Sullivan, C. Holly, SN. Cuff and J. Savino, "An artificial neural network as a model for prediction of survival in trauma patients: validation for a regional trauma area," *Journal of Trauma*, Vol. 49, no. 2 pp. 212-223, Aug 2000.
- [15] SM. Dirusso, AA. Chahine, T. Sullivan, D. Risucci, P. Nealon and S. Cuff, "Development of a model for prediction of survival in pediatric trauma patients: comparison of artificial neural networks and logistic regression," *Journal of Pediatric Surgery*, Vol. 37, no. 7, pp. 1098-1104, July. 2002.
- [16] 이주형, 최재림, 정상원, 김덕원, "출혈성 쇼크를 일으킨 환자에서 인공신경망을 이용한 생존율 예측," *응급의학회지*, 제21권, 제3호, 1-7쪽, 2010년 6월.
- [17] G. Gutierrez, H. D. Reines and M. E. Wulf-Gutierrez, "Clinical review: hemorrhagic shock," *Critical Care*, Vol. 8, no. 5, pp. 373 - 381, Oct. 2004.
- [18] J. Heaton, *Introduction to neural networks for JAVA, Second Edition*, Heaton Research, pp. 158-159, 2008.
- [19] P. N. Tan, M. Steinbch and V. Kumar, *Introduction to data mining*, Addison Wesley, pp. 250-271, 2005.
- [20] I.A. Basheer and M. Hajmeer, "Artificial neural networks: fundamentals, computing, design, and application," *Journal of Microbiological Methods*, Vol. 43, no. 1, pp. 3-31, Dec. 2000.
- [21] S. Y. Peng, K. C. Wu, J. J. Wang, J. H. Chung, S. K. Peng and Y. H. Lai, "Predicting postoperative nausea and vomiting with the application of an artificial neural network," *British Journal of Anaesthesia*, Vol. 98, no. 1. pp. 60-65, Aug. 2007.

저 자 소 개



장 경 환(학생회원)
2010년 연세대학교
의용전자공학과(공학사)
2010년~현재 연세대학교 대학원
생체공학협동과정
(석·박사 통합과정)

<주관심분야: 생체신호 계측 및 분석, 의료기기>



유 태 근(학생회원)
2008년 서울대학교
기계·항공공학부(공학사)
2010년 서울대학교 대학원
기계·항공공학부
(공학석사)
2010년~현재 연세대학교
의학전문대학원

<주관심분야: 생체신호 계측 및 분석, 의료기기>



남 기 창(평생회원)
1997년 연세대학교
의용전자공학과(공학사)
1999년 연세대학교 대학원 생체
공학협동과정(공학석사)
2004년 연세대학교 대학원 생체
공학협동과정(공학박사)

2004년~2005년 연세대학교 의과대학
의학공학교실 연구강사
2005년~2006년 SIEMENS 선임연구원
2006년~2007년 일본 National Institute of
Advanced Industrial Science and
Technology (Post Doc.)
2007년~2010년 한국전기연구원 선임연구원
2010년~현재 연세대학교 의과대학 의학공학교실
세브란스병원 의료기기 임상시험센터
연구조교수

<주관심분야: 생체신호계측, 생체신호처리, 의료
기기>



최 재 림(학생회원)
2010년 연세대학교
의용전자공학과(공학사)
2010년~현재 연세대학교 대학원
생체공학협동과정
(석사과정)

<주관심분야: 생체신호 계측 및 분석, 의료기기>



권 민 경(학생회원)
2010년 인제대학교
의용공학과(공학사)
2010년~현재 연세대학교 대학원
의과학과(석사과정)

<주관심분야: 생체신호 계측 및 분석, 의료기기>



김 덕 원(평생회원)-교신저자
1976년 서울대학교 공과대학
(공학사)
1980년 Northwestern University
전자공학(MS)
1986년 The Univ. of Texas at
Austin 의공학(Ph.D)

1987년~현재 연세대학교 의과대학 의학공학교실
(조교수, 부교수, 교수)

2006년~현재 연세대학교 의과대학 BK21
의과학과 교수

2008년 대한전자공학회 부회장 겸 시스템 및
제어 소사이어티 회장

<주관심분야: 생체신호계측, 의료기기, 전자파 유
해성>