

지원벡터기계를 이용한 출혈을 일으킨 흰쥐에서의 생존 예측

장경환^{1,2} · 최재림^{1,2} · 유태근³ · 권민경^{2,4} · 김덕원^{1,2,3,4}

¹연세대학교 생체공학협동과정, ²연세대학교 의과대학 의학공학교실,
³연세대학교 의학전문 대학원, ⁴연세대학교 의과대학 의과학과

Survival Prediction of Rats with Hemorrhagic Shocks Using Support Vector Machine

K. H. Jang^{1,2}, J. L. Choi^{1,2}, T. K. Yoo³, M. K. Kwon^{2,4} and D. W. Kim^{1,2,3,4}

¹Graduate Program in Biomedical Engineering, Yonsei University

²Department of Medical Engineering, Yonsei University College of Medicine

³Department of Medicine, Yonsei University College of Medicine

⁴Brain Korea 21 Project for Medical Science, Yonsei University, Seoul, Korea

(Received October 18, 2011. Accepted December 22, 2011)

Abstract: Hemorrhagic shock is a common cause of death in emergency rooms. Early diagnosis of hemorrhagic shock makes it possible for physicians to treat patients successfully. Therefore, the purpose of this study was to select an optimal survival prediction model using physiological parameters for the two analyzed periods: two and five minutes before and after the bleeding end. We obtained heart rates, mean arterial pressures, respiration rates and temperatures from 45 rats. These physiological parameters were used for the training and testing data sets of survival prediction models using an artificial neural network (ANN) and support vector machine (SVM). We applied a 5-fold cross validation method to avoid over-fitting and to select the optimal survival prediction model. In conclusion, SVM model showed slightly better accuracy than ANN model for survival prediction during the entire analysis period.

Key words: hemorrhagic shock, artificial neural network, support vector machine, 5-fold cross validation, survival prediction

1. 서 론

2010년 WHO(world health organization)의 보고에 따르면, 전 세계적으로 전체 사망의 14%가 상해로 인해 사망에 이르게 되고 그 사망 중 1/3의 직접적인 원인은 출혈성 쇼크이다[1,2]. 쇼크란 조직에 필요한 산소 요구량과 산소 공급 간의 불균형에 의해 유발되는 임상 증후군을 말하며 이러한 조직의 산소 불균형 상태는 모든 형태의 쇼크에서 치명

적이다[3]. 쇼크 상태가 상당히 진행된 경우에는 점차 임상 양상이 뚜렷해지므로 진단에 어려움은 없으나, 이미 주요 장기가 손상되어 치료에 대한 효과가 좋지 않다. 반면에 쇼크 초기 상태에서는 뚜렷한 임상 양상을 확인하는 것이 쉽지 않아 진단과 치료가 지연될 수 있다. 따라서 쇼크의 초기 상태에 대한 평가와 이에 따른 치료가 매우 중요하기 때문에, 이를 위한 다양한 시도가 있었다. 그 예로 최근 기계학습 방법들을 이용한 다양한 시도가 늘어나고 있다[4-6].

본 연구에서는 흰쥐의 대퇴부정맥을 통해 일정량의 출혈을 유도하면서 출혈 종료 전 후의 구간에서 심박수(heart rate, HR), 평균 동맥압(mean arterial pressure, MAP), 호흡수(respiration rate, RR) 및 체온(temperature, TEMP)의 생체 신호를 획득하여 출혈로 인한 쇼크 발생 시 생존을 상당히 정확하게 예측할 수 있는 생존 예측 모델을 생성 및

Corresponding Author : 김덕원
서울특별시 서대문구 연세로 50 연세대학교 의과대학 의학공학교실
TEL: +82-2-2228-1920 / FAX: +82-2-363-9923
E-mail: kdw@yuhs.ac
본 연구는 2010년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2009-0083613).

검증하여 최적의 생존 예측 모델을 제시하였다. 예측 모델로는 인공신경망(artificial neural network, ANN)과 최근 많이 연구되고 있는 분류 방법인 지원벡터기계(support vector machine, SVM)를 사용하였다. 객관적으로 우수하고 일반적인 생존 예측 모델을 선정하기 위하여 5-fold cross validation을 이용하여 인공신경망과 지원벡터기계에서 최적의 생존 예측 모델 선정하였고 그 성능을 비교하였다.

II. 본 론

1. 동물실험준비

본 연구의 동물실험은 체중 300-360 g의 45 마리 수컷 흰쥐(Sprague-Dawley rats)를 대상으로 복강 내 주사로 마취한 후(Zoletil 50, Virvac, France) 양와위(supine position)로 고정하였다. 양쪽 서혜부(inguinal area)에 최소한의 절개를 한 후 동맥혈압 측정을 위하여 우측 대퇴동맥에 24 gauge 카테터(Becton Dickinson Korea, Korea)를 삽입하였고, 출혈을 위해 좌측 대퇴정맥에 22 gauge 카테터를 삽입하였다. 심전도 측정을 위하여 양쪽 앞 다리와 뒤쪽 오른쪽 다리에 침습적인 바늘 전극을 삽입하였으며, 호흡수와 체온 측정을 위하여 흉곽에 호흡벨트를 부착하였으며 동물용 직장온도계를 삽입하였다. 그림 1은 동물실험을 위한 준비

2

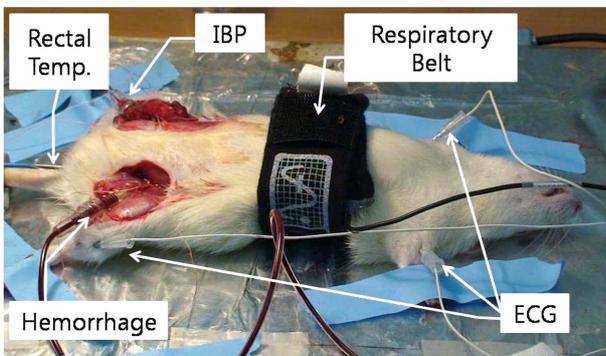


그림 1. 동물실험준비 장면[7]

Fig. 1. Photo of rat experimental setup[7]

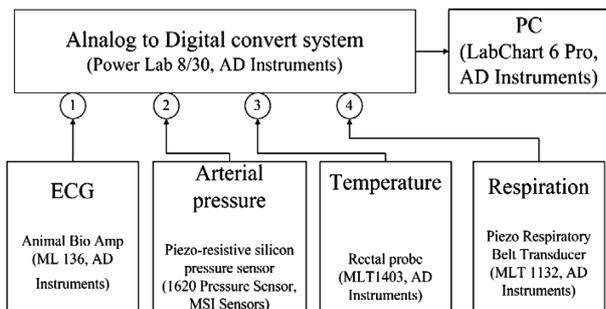


그림 2. 측정시스템의 블록 다이어그램[7]

Fig. 2. Block diagram of measurement system[7]

장면이다. 또한 정량적으로 출혈량을 제어하기 위하여 출혈 유도펌프(Pump 11 plus, Harvard Apparatus, USA)를 사용하여 출혈을 일으켰다. 그림 2의 블록 다이어그램과 같이 심전도, 동맥압, 호흡수, 체온의 생체신호 측정은 상용화된 제품인 PowerLab 8/30(AD Instruments, USA)를 사용하였으며, 1 kHz의 샘플링 주파수로 측정하였다. 획득한 모든 신호는 컴퓨터로 전송된 후 LabChart 6 Pro(AD Instruments)를 사용하여 분석하였다. 좀 더 자세한 내용은 Lee 등[7]을 참조.

2. 데이터 획득(Data Acquisition)

표 1과 같이 45마리의 흰쥐를 출혈량에 따라 15 마리씩 세 군으로 나누었고 각 군을 나누는 출혈량의 기준은 체중 100 g당 2.0 ml, 2.5 ml, 3.0 ml이며, 이는 전체 혈액 중 32.8%, 41.0%, 49.2%의 출혈에 해당하는 양이다[6-8]. 세 군으로 나누어진 흰쥐로부터 생존 예측 모델을 구축하기 위해 심박수, 평균 동맥압, 호흡수 및 체온을 측정하였다. 생체 신호 데이터는 그림 3과 같이 출혈 종료(지혈) 시점인 30분을 기준으로 25-30분(I 구간), 30-35분(II 구간), 28-30분(III 구간), 30-32분(IV 구간), 총 4개의 구간에 대하여 1분 평균값을 구하였다. 출혈 환자의 응급실 도착, 지혈 과정, 지혈 후 환자 관찰 등, 실제 응급 상황을 모사하기 위하여 출혈 종료 시점을 기준으로 데이터 분석 구간을 다르게 하여 분석

표 1. 흰쥐 세 그룹의 특성

Table 1. Three different groups of rats

Rats (weight)	Sprague-Dawley rats (300-350 g)		
Number of rats (n = 45)	15	15	15
Hemorrhagic rate (mL/100 g/15min)	2	2.5	3
Hemorrhagic ratio (%)	32.8	41.0	49.2
Shock class	III	IV	IV

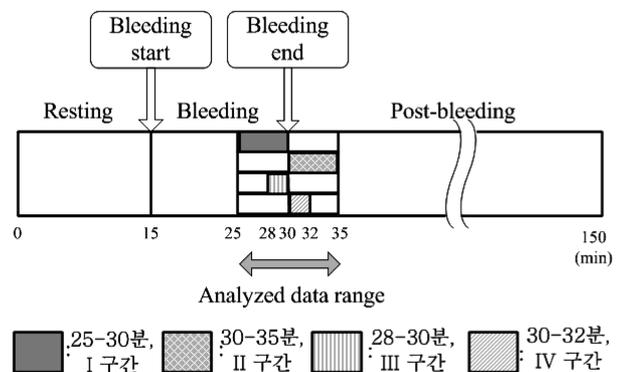


그림 3. 흰쥐의 출혈성 쇼크 실험 과정 및 생체 신호 분석 구간

Fig. 3. Experimental protocol of hemorrhagic shock using rats and four analyzed periods of physiological parameters

하였다. 여기서 출혈 종료 전 구간의 생존 예측 모델은 지혈 전의 환자 상태를 진단하기 위함이고, 출혈 종료 후 구간의 생존 예측 모델은 지혈 후 실제 지혈이 잘 되었는지를 판단하기 위함이다. 또한 환자의 생명을 다투는 응급 상황에서 좀 더 신속하고 정확한 생존 예측 모델을 선정하기 위하여 분석 구간의 길이를 각 2분과 5분으로 다르게 적용하여 분석하고 비교하였다. 총 데이터 세트의 개수는 표 2와 같이 I, II 분석 구간의 경우 225개(1 set/min × 5 min × 45 rats)의 데이터 세트가 만들어 지고, III, IV 분석 구간의 경우 90개(1 set/min × 2 min × 45 rats)의 데이터 세트가 만들어졌다. 총 150분 간 실험이 진행되었고, 사망을 판단하는 기준은 평균 동맥압이 0 mmHg로 측정되는 시점으로 규정하였다[9]. 각각의 데이터 세트는 측정된 4가지 생체 신호와 생존 여부의 정보를 가진 독립적인 데이터 세트로 이루어지며, 생존 예측 모델 훈련과 평가에 사용되었다.

3. 생존 예측 모델

출혈을 일으킨 흰쥐로부터 획득한 생체 신호는 분석 구간에 따라 각각 225개, 90개의 데이터 세트로 표 2와 같이 중복을 피하여 무작위로 훈련 데이터 세트와 평가 데이터 세트로 나누었다. 여기서 훈련 데이터 세트는 5-fold cross validation을 위하여 사용되며, 이를 통해 생존 예측 모델의 훈련 및 검증이 이루어진다. 또한 평가 데이터 세트를 적용하여 선정된 생존 예측 모델을 평가하고, 그 결과를 통해 인공신경망과 지원벡터기계의 성능을 비교하였다. 5-fold cross validation은 훈련 데이터 세트에 의한 과대적합(over-fitting)을 피하고, 일반화된 최적의 생존 예측 모델을

표 2. 분석 구간별 데이터의 생존 여부와 훈련 및 평가 데이터 세트 분포, (a) 출혈 종료 전과 후 각각 5분의 데이터 분포, (b) 출혈 종료 전과 후 각각 2분의 데이터 분포

Table 2. Distribution of each analysis period data divided into training and test set, survival. and death sets, (a) Distribution of 5 min data before and after bleeding end, (b) Distribution of 2 min data before and after bleeding end

(a)			
Group	Training set	Testing set	Total set
Survival set	65	30	95
Death set	85	45	130
Total set	150	75	225
(b)			
Group	Training set	Testing set	Total set
Survival set	25	13	38
Death set	35	17	52
Total set	60	30	90

선정하기 위해 적용되었다. 인공신경망과 지원벡터기계의 분석을 위하여 MATLAB Version 2008a(Mathworks Inc, Natick, USA)을 사용하였다.

(1) 인공신경망

인공신경망은 인간의 뇌 구조를 파악하여 그와 비슷한 역할을 할 수 있도록 가상의 모델을 구현하는 알고리즘으로, 본 연구에서 사용된 인공신경망의 구조는 그림 4(a)와 같이 일반적으로 사용되고 있는 다층 퍼셉트론(multi-layer perceptron)을 적용하였다. 적용된 다층 퍼셉트론은 각각 1개의 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성되어 있다. 훈련 방법은 빠른 속도로 국소 최적해를 찾는 Levenberg-Marquardt 역전파(back-propagation) 방법을 사용하였고, epoch는 500회이며, 평균 오차범위가 10^{-5} 이하일 경우 모델 생성을 종료하였다. 역전파 알고리즘은 입력 정보가 가중치를 통하여 순방향으로 전달되어 나타난 출력값과 실제 출력값 간의 오차를 역방향으로 전파하여 오차가 최소가 되도록 가중치를 조정하는 방법이다[10]. 역전파 알고리즘을 사용한 이유는 다층 퍼셉트론 모델 생성 시 훈련에 용이하며 다양한 분야에서 널리 활용되고 있기 때문이다.

인공신경망의 입력 노드는 심박수, 평균 동맥압, 호흡수, 체온이고, 출력 노드는 생존 또는 사망의 정보를 나타낸다. 은닉노드의 수는 인공신경망의 구조 설계 시 모델의 성능에 큰 영향을 미친다[11]. 따라서 은닉 노드의 수는 최적의 인공신경망 모델을 결정하는데 중요하다. 일반적으로 은닉 노드의 수는 시행오차를 통한 경험적 방법으로 결정되지만, 최근 은닉 노드 개수를 입력 노드와 출력 노드 사이의 수, 입력 노드와 출력 노드 수의 합에 2/3를 곱한 수, 또는 입력 노드의 두 배 이하의 수로도 제시하고 있다[11]. 따라서 본 연구에서는 은닉 노드의 수를 2-5개로 변경하여 최적의 성능을 가지는 은닉 노드의 수를 찾아 제안하였다. 인공신경망의 단점 중 하나는 형성된 모델이 훈련 데이터 세트에 최적화되는, 과대적합을 가져와 모델의 일반성이 떨어질 수 있다는 것이다[12]. 따라서 5-fold cross validation과 평가 데이터를 이용한 모델 검증을 통해 적절한 인공신경망의 구조 설계가 필요하다.

(2) 지원벡터기계

지원벡터기계는 다층 퍼셉트론을 비롯한 통계적 패턴인식 방법과 같은 전통적인 학습방식들의 대안학습방법으로, 분류 및 예측 기법에 사용되는 기계 학습법의 일종이다[13]. 복잡한 데이터 패턴을 커널함수(kernel function)를 이용하여 고차원 특징공간으로 변환시킬 수 있다는 점과 최적의 대역적인 식별이(global minima) 가능하다는 특징이 있다[14]. 또

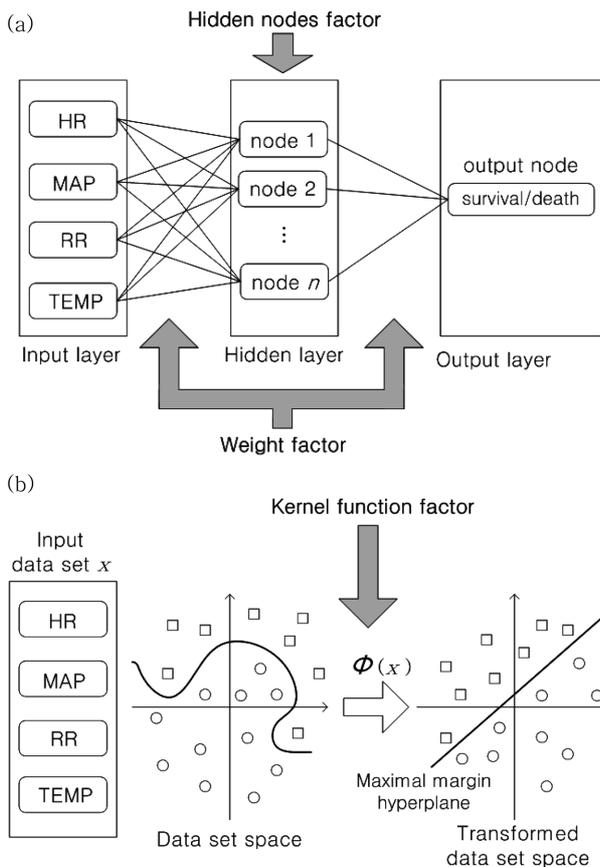


그림 4. 예측 모델과 변수에 대한 도식, (a) 인공신경망의 은닉 노드와 가중치 변수, (b) 지원벡터기계의 커널함수 변수

HR: 심박수, MAP: 평균 동맥압, RR: 호흡수, TEMP: 체온

Fig. 4. ANN and SVM with their variables, (a) Weight and hidden nodes of ANN, (b) Kernel function factor of SVM

HR: heart rate, MAP: mean arterial pressure, RR: respiration rate, TEMP: temperature

한, 지원벡터라는 훈련 데이터의 부분집합을 통하여 분류의 경계를 표현한다. 이를 통해 분류 경계를 이루는 초평면(hyper-plane)과 지원 벡터와의 거리가 최대가 되도록 하는 훈련 과정을 거쳐 최적의 분류 모델을 구축한다. 지원벡터기계 역시 인공신경망과 마찬가지로 생존 예측 모델을 생성하기 위하여 심박수, 평균 동맥압, 호흡수, 체온을 입력정보로 사용하였으며, 출력값은 흰쥐의 생존 혹은 사망 여부이다. 지원벡터기계의 구조 설계 시 가장 큰 영향을 미치는 것은 데이터를 고차원으로 사상시키는 커널함수 이다. 따라서 본 연구에서는 커널함수를 쓰지 않는 모델과 커널함수가 각각 2차, 4차, 가우시안 함수들로 구성된 지원벡터기계 모델을 설계하여 생존 예측 모델을 제안하였다. 생존 예측 모델의 지원벡터기계 도식은 그림 4(b)와 같다.

4. 5-fold cross validation 및 생존 예측 모델 선정 방법

5-fold cross validation은 인공신경망과 지원벡터기계를

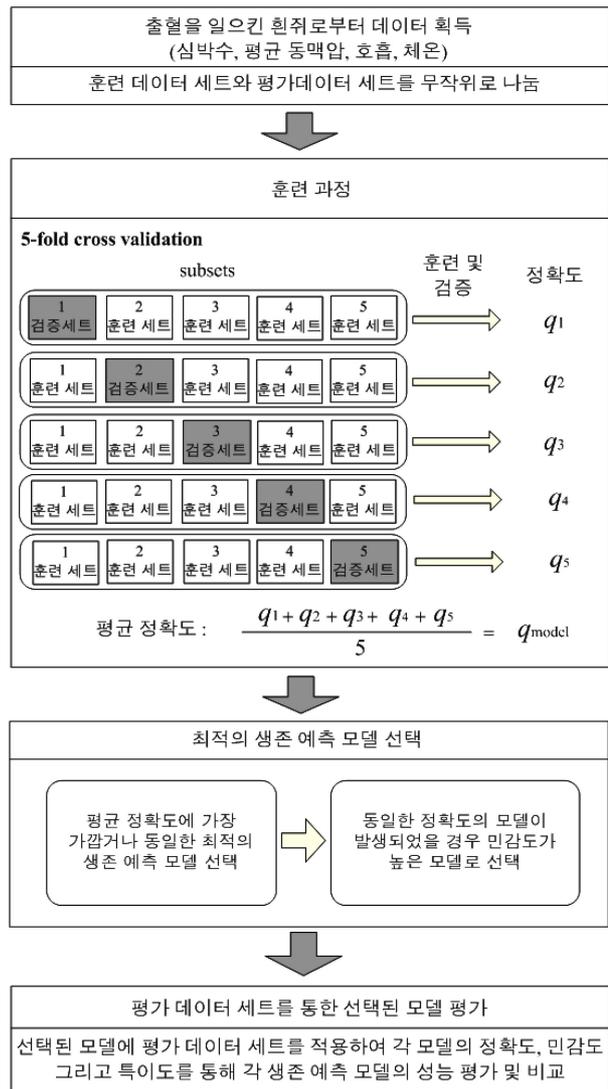


그림 5. 5-fold cross validation을 통한 생존 예측 모델 선정 흐름도
Fig. 5. Flow chart for the selection of a survival prediction model using 5-fold cross validation

통해 생성된 생존 예측 모델이 훈련 데이터 세트에 의한 과대적합을 피하고 최적의 생존 예측 모델을 선정하기 위하여 사용하였다. 그림 5와 같이 5-fold cross validation의 과정은 훈련 데이터 세트와 평가 데이터 세트를 중복을 피하여 무작위로 나눔 후, 나누어진 훈련 데이터 세트를 5등분한다. 5등분된 부분 훈련 데이터 세트 중 1개는 검증 데이터 세트로, 나머지 4개는 훈련 데이터 세트로 사용되어 생존 예측 모델을 만든다. 이 과정을 검증 데이터 세트를 다르게 하여 5회 반복 시행하였다. 이를 통해 생성된 5개의 모델의 정확도(accuracy)를 평균하였다. 이 정확도의 평균값은 각 분류기의 성능을 객관적으로 나타내는 지표라 할 수 있으며, 최적의 생존 예측 모델을 선정하기 위해 평균 정확도에 가장 근접한 모델을 선택하였다[15]. 그러나 평균 정확

도에 근접한 모델을 선택할 경우 검증 데이터 세트의 수가 많지 않아 5개의 생존 예측 모델의 정확도가 평균값과 일치 혹은 동일하게 근접한 모델이 존재할 수 있다. 이 경우 민감도 (sensitivity)와 특이도 (specificity)를 기준으로 모델을 선정할 수 있는데 이들의 정의는 다음 식 (1), (2), (3)과 같다.

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (1)$$

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (2)$$

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

TP(true positive)는 진양성으로, 사망한 개체를 사망군으로 예측한 사례의 수, TN(true negative)는 진음성으로, 생존한 개체를 생존군으로 예측한 사례의 수, FP(false positive)는 위양성으로, 생존한 개체를 사망군으로 예측한 사례의 수, FN(false negative)는 위음성으로, 사망한 개체를 생존군으로 예측한 사례의 수를 말한다. 최적의 모델 선택 시 고려해야 하는 사항은 구축된 생존 예측 모델을 통해 더 위중한 환

자들에게 보다 빠른 치료를 받게 하여 위급한 환자의 생존율을 높이는 것이다. 따라서 만약 동일한 정확도의 모델이 존재한다면 사망한 개체를 더 잘 판단하는 민감도가 더 높은 모델을 선택했다. 선택된 모델은 성능 평가를 위해 평가 데이터 세트에 적용시켰다.

최적의 생존 예측 모델 생성 과정 시 훈련 데이터가 많지 않아 무작위로 선택하는 과정을 거칠 경우 편향된 데이터 조합이 생길 수 있다. 따라서 본 연구에서는 이를 보완하기 위해 그림 5의 과정을 10회 반복하여 구한 평균 민감도, 특이도와 정확도를 바탕으로 최적의 생존 예측 모델을 제안하여 보다 객관적으로 생존 예측 모델의 성능을 평가하였다.

III. 결 과

인공신경망과 지원벡터기계의 모델 생성시간을 비교해보면 인공신경망은 약 8초이며 지원벡터기계는 약 1초미만으로 지원벡터기계가 훨씬 빠르게 생존 예측 모델을 생성하는 것을 확인하였다. 표 3은 5-fold cross validation을 통해 생성된 인공신경망과 지원벡터기계의 생존 예측 모델들의 각

표 3. 5-fold cross validation을 통해 생성된 생존 예측 모델의 정확도 (평균 ± 표준편차, 10회 반복)

Table 3. Accuracy of the survival prediction models using 5-fold cross validation (mean ± standard deviation, 10 times repetitions)

Model	Period (min)	Number of hidden node	Sensitivity (%)	Specificity (%)	Accuracy (%)
ANN	25-30 (I) (n = 150)	2	80.2 ± 7.2	91.0 ± 7.1	84.7 ± 3.2
	30-35 (II) (n = 150)	2	95.0 ± 3.2	97.7 ± 3.7	96.0 ± 2.6
	28-30 (III) (n = 60)	2	79.1 ± 10.5	92.5 ± 12.7	85.0 ± 5.3
	30-32 (IV) (n = 60)	2	86.9 ± 9.1	94.0 ± 9.7	90.0 ± 3.5
Model	Period (min)	Kernel function	Sensitivity (%)	Specificity (%)	Accuracy (%)
SVM	25-30 (I) (n = 150)	Gaussian	86.8 ± 8.3	88.3 ± 7.8	87.0 ± 4.3
	30-35 (II) (n = 150)	Gaussian	97.0 ± 3.2	99.4 ± 1.9	98.0 ± 1.7
	28-30 (III) (n = 60)	Non-kernel	85.5 ± 2.7	97.5 ± 7.9	90.8 ± 2.6
	30-32 (IV) (n = 60)	Gaussian	91.3 ± 6.0	96.3 ± 7.8	92.5 ± 2.6

표 4. 5-fold cross validation을 통해 생성된 생존 예측 모델에 평가 데이터 세트를 적용한 정확도(평균 ± 표준편차, 10회 반복)

Table 4. Accuracy of the selected survival prediction models with the test data set (mean ± SD, 10 times repetitions)

Model	Period (min)	Number of hidden node	Sensitivity (%)	Specificity (%)	Accuracy (%)
ANN	25-30 (I) (n = 75)	2	86.4 ± 4.4	87.3 ± 8.9	86.8 ± 3.8
	30-35 (II) (n = 75)	2	92.7 ± 5.6	97.3 ± 3.4	94.5 ± 2.8
	28-30 (III) (n = 30)	2	87.1 ± 10.3	89.2 ± 11.0	88.0 ± 6.7
	30-32 (IV) (n = 30)	2	91.8 ± 6.3	95.4 ± 8.3	93.3 ± 4.2
Model	Period (min)	Kernel function	Sensitivity (%)	Specificity (%)	Accuracy (%)
SVM	25-30 (I) (n = 75)	Gaussian	90.9 ± 4.5	86.3 ± 7.3	89.1 ± 3.8
	30-35 (II) (n = 75)	Gaussian	97.3 ± 2.0	97.0 ± 1.9	97.3 ± 1.9
	28-30 (III) (n = 30)	Non-kernel	93.5 ± 7.6	88.5 ± 10.4	91.3 ± 4.5
	30-32 (IV) (n = 30)	Gaussian	93.5 ± 5.8	99.2 ± 2.4	96.0 ± 3.8

분석구간에서의 민감도, 특이도, 정확도를 보여주고 있다. 각 분류기의 최적의 생존 예측 모델을 선정한다면, 인공신경망의 경우 은닉 노드의 개수가 2인 경우 모든 분석 구간에서 정확도를 기준으로 가장 우수한 성능을 보였고, 지원벡터기계의 경우 I, II, IV 구간에서 가우시안 커널함수를 사용하였을 때, III 구간에서 커널함수를 사용하지 않았을 경우 우수한 정확도를 보였다.

표 4는 선정된 모델에 평가 데이터 세트를 적용한 결과이다. 평가 데이터를 적용한 결과, I, II, III, IV의 모든 구간에서 지원벡터기계가 인공신경망보다 조금 더 좋은 성능을 보이는 것을 확인하였다. 그러나 두 모델의 성능 차이는 크지 않았다. 출혈 종료 전후의 각 분류기의 성능을 비교해보면, 두 분류기 모두 출혈 종료 후 모델이 출혈 종료 전 모델보다 우수한 성능을 보였다. 그 이유는 출혈 종료 전의 생체 신호의 경우 생존군과 사망군의 생체 신호의 특징이 크게 다르지 않아 생존을 판단하기 쉽지 않고, 출혈 종료 후의 경우 생존군과 사망군의 생체 신호가 시간이 경과함에 따라 점차 극명하게 나누어지는 양상을 보이기 때문으로 사료된다. 출혈 종료 전 각 5분과 2분인 I, III 구간과 출혈 종료 후 각 5분과 2분인 II, IV 구간으로 분석 시간의 길이를 다르게 하여 생성된 모델의 성능의 경우, 인공신경망과 지원벡터기계 모두 출혈 종료 전에는 III 구간이, 출혈 종료 후에는 II 구간이 더 좋은 성능을 나타내었다. 그러나 I, III 구간 모델의 성능 차이와 II, IV구간 모델의 성능의 차이가 약 2% 내외의 작은 차이를 보였다. 따라서 신속한 진단과 치료가 중요시 되는 위중한 외상환자의 경우 짧은 측정시간과 우수한 정확도를 가지는 출혈 종료 전 2분과 후 2분 구간의 지원벡터기계 모델의 적용이 적절하다고 사료된다.

IV. 결 론

고전적인 회귀분석보다 예측력이 높으며 특히 상관관계가 복잡한 문제에 대하여 비교적 잘 분석하는 인공신경망의 장점에도 불구하고 과대적합, 지역 최소값 문제는 인공신경망의 가장 큰 단점으로 남아있다. 지원벡터기계는 인공신경망의 대안적인 방법으로 지역 최소값 문제를 보완한 데이터 분류 기법이다. 따라서 본 연구에서는 지원벡터기계를 추가적으로 사용하여 더 좋은 성능의 생존 예측 모델을 제안하였다.

기존 연구에서 Lee 등[6]은 인공신경망 모델만을 사용하여 출혈성 쇼크를 일으킨 흰쥐에서의 생존율을 예측하였다. 또한 검증 과정을 거치지 않아 객관적인 모델로 제시하기에는 부족함이 있다. 따라서 본 연구에서는 인공신경망 보다 더 좋은 성능의 지원벡터기계 모델을 추가 시행하고 검증 과정을 통해 더욱 객관적이고 우수한 성능의 모델을 제시하였다. 출혈 종료 시점을 기준하여 I, II, III, IV 구간에서의 예측 모

델을 구축함으로써, 환자의 상태에 따른 생존 예측 모델을 제안하였다. 또한, 5-fold cross validation을 통해 일반화된 최적의 생존 예측 모델을 선정하고 평가 데이터 세트에 적용하였다. 인공신경망과 지원벡터기계의 성능을 비교해 본 결과, 지원벡터기계가 인공신경망보다 짧은 모델 생성시간을 가지며 우수한 성능을 보이는 것을 확인하였다.

그러나, 본 실험에서 제시한 모델은 우수한 성능에도 불구하고 출혈량을 일정하게 제어하였기 때문에 실제 임상 상황과는 차이가 있다. 또한 일반적인 동물 실험 모델은 마취 상태에서 진행이 되며, 이는 심혈관 기능, 대사 기능 등에 영향을 줄 수 있기 때문에, 임상에 바로 적용하기에는 무리가 있다[16]. 따라서 추후 연구로는 비제어 출혈(uncontrolled hemorrhage shock) 모델을 통해 얻은 동물실험과 궁극적으로는 실제 임상 데이터를 이용한 생존 예측 모델을 제안한다.

본 연구에서는 시간과의 싸움이라 할 수 있는 출혈성 쇼크의 조기 진단을 임상에서 신속하고 측정이 용이한 변수를 통해 생존 예측 모델을 제안하였다. 이 연구를 바탕으로 추후 실제 임상에서 출혈성 쇼크를 높은 정확도로 조기 진단하는 생존 예측 모델이 구축된다면 다수의 외상환자 발생 시 신속히 쇼크의 경중을 판단하여 사망 위험군 환자들을 우선적으로 치료할 수 있을 것이다.

참고문헌

- [1] World Health Organization, *World health statistics 2010*, Geneva, Switzerland: World Health Organization Press, 2010, pp. 62-70.
- [2] C.J. Murray, and A.D. Lopez, "Alternative projections of mortality and disability by cause 1990-2020: global burden of disease study," *Lancet*, vol. 349, no. 9064, pp. 1498-1504, 1997.
- [3] V.J. Markovchick, and P.T. Pons, *Emergency medicine secrets, 4th edition*, Philadelphia, USA: Hanley & Belfus, 2006, pp. 28-32.
- [4] M. Wilson, D.P. Davis, and R. Coimbra, "Diagnosis and monitoring of hemorrhagic shock during the initial resuscitation of multiple trauma patients: a review," *J Emerg Med*, vol. 24, no. 4, pp. 413-422, 2003.
- [5] S.M. Dirusso, T. Sullivan, C. Holly, S.N. Cuff, and J. Savino, "An artificial neural network as a model for prediction of survival in trauma patients: validation for a regional trauma area," *J of Trauma*, vol. 49, no. 2 pp. 212-223, 2000.
- [6] J.H. Lee, J.L. Choi, S.W. Chung, and D.W. Kim, "A survival prediction model for rats with hemorrhagic shock using an artificial neural network," *Journal of The Korean Society of Emergency Medicine*, vol. 21, no. 3, pp. 321-327, 2010.
- [7] T.H. Lee, J.H. Lee, J.R. Choi, D.I. Yang, and D.W. Kim, "Blood loss prediction of rats in hemorrhagic shock using a linear regression model," *IEEK*, vol. 47, no 1. pp. 56-61, 2010.
- [8] K.H. Jang, T.K. Yoo, J.Y. Choi, K.C. Nam, J.L. Choi, M.K. Kwon, and D.W. Kim, "Comparison of survival predictions for rats with hemorrhagic shocks using an artificial neural

- network and support vector machine,” in *Proc. 33rd EMBS*, Boston, USA, Aug 30-Sep 3, 2011, pp. 2.
- [9] A. Takasu, T. Sakamoto, and Y. Okada, “Effect of induction rate for mild hypothermia on survival time during uncontrolled hemorrhagic shock in rats,” *J Trauma*, vol. 61, no. 6, pp. 1330-1335, 2006.
- [10] C.B. Ahn, T.Y. Lee, and S.H. Lee, “Automatic EEG and artifact classification using neural network,” *J of KOSOMBE*, vol. 16, no. 2, pp. 157-166, 1995.
- [11] J. Heaton, *Introduction to neural networks for JAVA, Second Edition*, La Vergne TN, USA: Heaton Research, 2008, pp. 158-159.
- [12] I.A. Basheer, and M. Hajmeer, “Artificial neural networks: fundamentals, computing, design, and application,” *J Micro-biol Methods*, vol. 43, no. 1, pp. 3-31, 2000.
- [13] J.W. Kwon, H.K. Kang, Y.M. Ro, and S.M. Kim, “A hierarchical microcalcification detection algorithm using SVM in Korean digital mammography,” *J of KOSOMBE*, vol. 27, no. 5, pp. 291-299, 2006.
- [14] P.N. Tan, M. Steinbach, and A. Karim, *Introduction to data mining*, USA: Addison Wesley, 2005, pp. 250-271.
- [15] 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,” *Br J Anaesth*, vol. 98, no. 1, pp. 60-65, 2007.
- [16] W.J. Meijerink, P.E. Molina, and N.N. Abumrad, “Mammalian opiate alkaloid synthesis: lessons derived from plant biochemistry,” *Shock*, vol. 12, no.3, pp. 165-173, 1999.