

Support Vector Machine을 이용한 생체 신호 분류기 개발

홍동권* · 채용웅**

Development of a Clinical Decision Support System Utilizing Support Vector Machine

Dong-Kwon Hong* · Yong-Yoong Chai**

요약

피부 저항을 이용한 생체 신호는 스트레스성 질환에 따라 각각 다른 특성을 보이고 있으며 이 특성을 이용하여 스트레스성 질환을 진단하는 생체진단 장비들이 개발 되었으며, 장비들은 피부 저항 측정기에서 측정된 신호를 해석하기 쉽게 출력해주며, 그 분야의 전문가가 출력 신호를 직접 보고 어떤 스트레스성 질환의 가능성이 높은지를 판단하게 된다. 하지만 각 측정 대상자에게서 측정된 생체 신호를 분석하여 측정 대상자가 어떤 스트레스성 질환을 가지고 있는지를 사람이 정확히 판단하기는 매우 어려울 뿐만 아니라 판단의 결과가 잘못될 가능성도 매우 높다. 이런 문제점을 해결하기 위하여 본 연구에서는 머신러닝 기법을 이용하여 측정된 신호가 어떤 스트레스성 질환의 신호에 해당하는지를 판단하는 기능을 구현하였다. 측정 장비의 낮은 컴퓨팅 능력을 고려하여 분류 기법은 SVM을 사용하였으며, 훈련 데이터와 테스트 데이터는 13개의 질환을 중심으로 오차범위 5를 사용하여 각 질환 당 1,000개를 랜덤하게 생성하여 사용하였다. 모의실험 결과에서 90% 이상의 판단 정확도를 보였으며 앞으로 측정 장비가 실제로 환자들에게 적용되면 다시 생성된 데이터로 분류기를 재훈련 할 수 있게 구성하였다.

ABSTRACT

Biomedical signals using skin resistance have different characteristics according to stress diseases. Biological diagnostic devices for diagnosing stress diseases have been developed by using these characteristics, and devices have been developed so that the signals measured by the skin storage meter can be easily analyzed. Experts in the field will look directly at the output signal to determine the likelihood of any stress disorder. However, it is very difficult for a person to accurately determine whether a person to be measured has a stress disorder by analyzing a bio-signal measured by each person to be measured, and the result of the judgment is very likely to be wrong.

In order to solve these problems, we implemented the function of determining the signal of a stress disorder by using the machine learning technique. SVM was used as a classification method in consideration of low computing ability of measurement equipment. Training data and test data were randomly generated for each disease using error range 5 based on 13 diseases. Simulation results showed more than 90% decision accuracy. In the future, if the measurement equipment is actually applied to the patients, we can retrain the classifier with the newly generated data.

키워드

Machine Learning, Support Vector Machine, Data Classification, Feature Selection, Libsvm
머신 러닝, 서포트 벡터 머신, 데이터 분류, 속성 추출, libsvm

* 계명대학교 컴퓨터공학전공(dkhong@kmu.ac.kr)

** 교신저자 : 계명대학교 전자공학전공

• 접수일 : 2018. 04. 20

• 수정완료일 : 2018. 05. 18

• 게재확정일 : 2018. 06. 15

• Received : Apr. 20, 2018, Revised : May. 18, 2018, Accepted : Jun. 15, 2018

• Corresponding Author : Yong-Yoong Chai

Dept. of Electronic Engineering, Keimyung University

Email : yychai@kmu.ac.kr

1. 서론

피부 저항을 이용한 생체 신호는 스트레스성 질환에 따라 다른 특성을 보이고 있다고 알려져 있다 [1-4]. 이 특성을 이용하여 스트레스성 질환을 진단하는 생체진단 시스템들이 개발 되었으며, 독일의 베가사가 개발한 피부저항측정기가 지금 현재 국내시장을 거의 독점하고 있다 [1-2]. 하지만 지금까지 개발된 장비들은 피부 저항 측정기에서 측정된 신호를 단순 출력하는 기능만을 가지고 있으며, 신호의 특성에 따라 어떤 종류의 스트레스성 질환의 가능성이 높은지를 해석하는 것은 그 분야의 전문가가 출력 신호를 직접 보고 전문가의 판단에만 의존하는 방식을 사용하여 왔다. 실제로 베가사의 피부저항측정기는 신체의 7곳에서 생체 신호를 측정하며, 그 측정 신호의 특성에 따라 측정 대상자를 13개의 클래스로 분류하는 방식을 사용한다 [2], [5-6]. 이때 각 측정 대상자에게서 측정된 생체 신호를 분석하여 측정 대상자가 어떤 스트레스성 질환을 가지고 있는지 즉 13개의 클래스 중 어느 클래스에 속하는지를 판단하는 것은 21가지의 신호 특성을 비교 (신체 1곳에서 3가지 특성이 있으며, 신체 7곳의 신호를 모두 비교)해야 하므로 사람이 정확히 판단하기는 매우 어려울 뿐만 아니라 판단의 결과가 잘못될 가능성도 매우 높다.

의료 분야에서 컴퓨터 즉 머신러닝을 활용한 판단 기능 (Computer-aided decision support in clinical medicine)의 향상은 매우 중요한 역할을 한다. 특히 의료분야에서 이 기능은 매우 필요한 분야로 의료 진단 지원 시스템(MDSS - Medical decision support systems)분야로 확대되어 오늘날 병원에서 널리 사용되고 있다. 이 기능은 여러 가지 이유로 아직 직접 판단을 결정 하는 것이 아니라 의사의 판단을 도와주는 보조 역할을 수행한다. 본 연구의 결과인 피부저항 측정 신호의 판단 기능도 측정자의 판단을 도와주는 역할을 할 것이며 최종 판단은 측정자에 의해 결정된다. 하지만 본 연구에서 개발된 피부 저항 측정 신호의 판단 지원 장비는 측정자의 판단 정확도를 향상 시키는데 크게 기여할 것으로 기대한다.

머신러닝을 이용한 분류 기법은 k-NN(: k-Nearest Neighbor), 결정트리, SVM(: Support Vector Machine), 인공신경망(artificial neural network), 랜덤

포리스트(Random Forest)와 같은 앙상블 트리, 딥 러닝 등 여러 가지 기법들이 제시되어 있다 [7]. 이 머신러닝 기법들은 데이터의 속성에 따라 조금씩 다른 성능을 보이지만 일반적으로 SVM은 다양한 데이터 집합에서 안정된 성능을 보인다 [7-9]. 뿐만 아니라 판단을 위해 사용하는 모델에 지지벡터(support vector)만 유지하면 되므로 본 연구에서 사용하는 라페판다와 같이 제한적인 성능을 보이는 장비에 가장 적절한 기법으로 판단되어 본 연구에서는 SVM을 사용한 분류 기법을 사용하였다.

II. 관련 연구

측정 장비에서 측정된 생체 신호는 연속된 값의 시퀀스로 표현된다. 측정된 연속된 값은 정확한 의미를 부여하기 어려워 효과적인 분류에 직접 사용되지 못한다. 본 연구에서는 측정된 신호에서 필요한 속성들을 추출해내고, 그 속성들을 바탕으로 머신러닝을 실행한다.

머신러닝(machine learning) 또는 기계학습으로 지칭되는 기법은 알고리즘에서 훈련 과정의 존재 유무에 따라 지도 학습(supervised learning) 또는 비지도 학습(unsupervised learning)으로 나누어진다 [3]. 본 연구에서 사용되는 입력 데이터의 분류 기법은 훈련 데이터를 사용하므로 지도 학습에 해당된다. 훈련 데이터는 속성 (a_1, a_2, \dots, a_n)과 미리 결정된 목적변수 (본 연구에서는 예측된 질병)로 구성되는 데이터로 구성된다.

머신러닝을 이용한 분류 기법은 k-NN, 결정트리, SVM, 인공신경망, 랜덤 포리스트, 딥 러닝과 같은 기법들이 제시되어 있다 [7]. 이 머신러닝 기법들은 데이터의 속성에 따라 조금씩 다른 성능을 보이지만 일반적으로 SVM은 가장 안정된 성능을 보인다 [7, 8]. 뿐만 아니라 판단을 위해 지지벡터(support vector)만 유지하면 되므로 라페판다와 같이 제한적인 성능을 보이는 장비에 가장 적절한 기법으로 판단된다.

SVM은 데이터를 분류할 때 최대 마진으로 데이터를 분류하기 위한 초평면 분리 (separating hyperplane)를 사용하는 기법이다. [그림 1]과 같은 2차원 데이터를 분류하는 분류선은 매우 많겠지만 최

대 마진을 얻는 분류선을 찾는 것이 분류 기법을 가장 안정되게 만드는 방법이다. SVM은 [그림 1]의 2차원 방법을 N차원으로 확장하고 N-1 차원의 초평면 분리식을 찾아낸다.




그림 1. SVM 최대 마진 분류
Fig. 1 SVM maximum margin classification

SVM에서 최대 마진 초평면 분리식을 찾는 것은 다음의 수식(1)에서 최대값을 찾는 것이 된다[10].

$$\max_{w,b} \left\{ \min_n (\text{label}_n \cdot (w^T x + b)) \cdot \frac{1}{\|w\|} \right\} \quad (1)$$

SVM은 과정이 매우 복잡하여 직접 구현하는 것보다는 이미 만들어진 라이브러리를 사용하는 것이 매우 효과적이다. SVM 라이브러리 중에서 libsvm은 위의 수식에서 최대값을 찾는 복잡한 과정을 C++ 프로그래밍 언어로 구현한 것이다[10]. 본 연구에서는 생체 신호를 분류하기 위하여 libsvm을 사용하여 SVM 분류기를 구축한다.

III. 측정된 생체 신호 관리

본 연구에서 생체 신호 측정 장비에는 윈도우 10이 실행되는 라떼판다를 사용하였다. 측정된 생체 신호의 차트 출력과 관리를 위한 프로그램 개발을 위하여 라떼판다의 윈도우 환경에는 비주얼 스튜디오(visual studio)를 설치하여 C#과 winform을 사용하여 프로그램을 구성하였다.

3.1 생체 신호의 저장 및 출력

장비에서 취득한 생체 신호를 저장할 테이블의 형식은 다음과 같다. 개인 정보에 해당하는 부분들은 본 연구와 연관 없는 부분이어서 저장하지 않는다.

```
CREATE TABLE bio_data {
  record_id number,
  machine_id varchar(10),
  patient_id varchar(10),
  body_part1 varchar(255), // 7곳의 생체 신호를 저장
  ...
  body_part7 varchar(255),
  measured_date date,
  measured_class number, // 분류된 내용
  primary key(record_id)
};
```

본 연구에서 사용하는 라떼판다는 CPU 성능과 물리적 공간이 제한적이어서 임베디드 DBMS인 SQLite[8]를 설치하여 생체 신호를 저장하였다. 따라서 각 측정 장비마다 따로 생체 신호를 저장할 수 있다. 하지만 특정 장비에서 측정된 내용으로만 훈련 데이터를 구성 하는 것은 왜곡된 결과를 얻을 수 있기 때문에 본 연구에서는 SQLite에 저장된 데이터를 중앙서버로 전송, 저장하는 기능을 추가하였다. 그 후 중앙 서버에 저장된 데이터에서 일부분을 훈련 데이터로 추출하여 사용하여 특정 장비에 의존적인 결과가 나오는 것을 방지하게 하였다.

3.2 속성 추출

측정된 원시 신호에서 각 측정 대상자들의 특성을 잘 파악하기 위하여 [그림 2]와 같은 신호로 변환된다.




그림 2. 변환된 생체 신호
Fig. 2 Transformed biomedical signals

[그림 2]의 변환된 신호에서 측정 대상자의 특성을 파악하기 위해 임상적으로 의미가 있다고 알려진 다음의 AA, PF, RF 3개의 값을 다음의 3가지 속성을 계산하여 사용한다[1].

$$AA = (A+B)/2$$

$$PF = D/C$$

$$RF = (E-F)/E$$

따라서 본 연구에서 사용하는 데이터는 7개의 각 신체 부분에서 측정된 [그림 2]의 데이터를 사용하므로 총 21개의 속성 값으로 변환된다. 다음 데이터 샘플은 libsvm 입력 형태로 변환된 측정 값 샘플들이다.

```

| 1:0.152558 2:-0.109301 3:-0.109301 4:-0.00799486 5:-0.8071
1 1:0.0996234 2:-0.130959 3:-0.130959 4:0.00844238 5:-0.8071
1 1:0.0210639 2:-0.18191 3:-0.18191 4:-0.0384627 5:-0.8063
1 1:0.0838621 2:-0.191494 3:-0.191494 4:-0.0220254 5:-0.8071
1 1:0.121035 2:-0.255034 3:-0.255034 4:0.0418517 5:-0.8071
1 1:0.0681007 2:-0.252387 3:-0.252387 4:-0.0524933 5:-0.8071
1 1:0.015166 2:-0.2505 3:-0.2505 4:-0.036056 5:-0.808387
1 1:0.168072 2:-0.313641 3:-0.313641 4:-0.0829611 5:-0.8071
    
```

그림 3. libsvm 입력 형식
Fig. 3 Format of libsvm input data

3.3 머신러닝을 이용한 생체 신호의 분류

본 연구에서는 C# winform 프로그램에서 C++ 로 생성된 libsvm을 사용하기 위해 만들어진 C# wrapper 중에서 LibSVMsharp를 사용하였다. 생성된

프로그램의 솔루션 라이브러리에서 winform 프로젝트에 libsvm이 포함된 것을 확인할 수 있다.

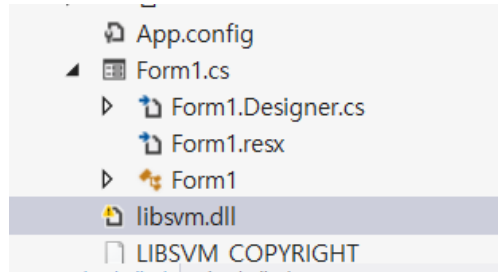


그림 4. 프로젝트에 포함된 libsvm.dll
Fig. 4 libsvm.dll in project files

3.3.1 분류기 훈련

분류기 훈련 과정은 먼저 훈련 데이터가 필요하다. 훈련 데이터가 저장된 파일을 만들어두고 그 파일을 SVMProblemHelper.Load로 읽어온다. 이때 각 속성들의 값이 서로 범위가 다를 경우 각 속성이 분류기에 주는 영향이 서로 다른 것을 막아주기 위해 반드시 스케일링(Scaling) 과정을 거친다. 본 연구에서도 각 속성 값은 -1과 1사이의 값으로 스케일링 과정을 거친 데이터를 다음과 같이 로드하여 사용하였다.

```

SVMProblem TrainingSet;
TrainingSet = SVMProblemHelper.Load(fullpathName);
    
```

훈련 데이터는 각 클래스에 100개의 데이터를 준비하였다. 각 클래스에 따른 100개의 데이터는 클래스 판단 기준이 되는 기본 값에서 오차범위 5를 사용하여 랜덤 함수를 사용하여 [그림 2]의 AA, PF, RF 값을 생성하였다.

훈련 데이터가 준비된 후 그 다음 과정은 SVM 분류기의 파라미터 설정 과정이다. 가장 일반적인 선택은 다음과 같다.

```

parameter.Type = SVMType.C_SVC;
parameter.Kernel = SVMKernelType.RBF;
    
```

```

    앞의 선택에 따라 C값과 gamma 값을 설정한다.
    parameter.C = Convert.ToInt32(textBox5.Text);
    parameter.Gamma
    =
    Convert.ToDouble(textBox6.Text);

```

k-fold cross validation 과정은 앞의 파라미터 설정이 적절한지를 확인하기 위한 과정이다. 파라미터 설정을 바꾸어가면서 k-fold cross validation 과정을 반복해서 적절하다고 판단되는 파라미터 설정을 채택한다. 이 과정은 그리드 탐색 방법을 사용하였으며 본 과정에서 설정된 값은 RBF 커널과 C 값, 감마 값이 각각 1로 설정되었다.

```

    TrainingSet.CrossValidation(parameter, nFold, out
    crossValidationResult);

```

파라미터 설정이 끝난 후 훈련 데이터를 이용하여 훈련 과정을 거친다. 그 다음 훈련된 모델을 파일에 저장해 두었다가 필요할 때 다시 로드해서 사용한다.

```

    model = TrainingSet.Train(parameter);
    SVM.SaveModel(model, FileName);

```

FileName에 저장된 파일이 훈련을 거친 SVM 모델이 된다.

분류기 테스트 파일은 훈련 파일과 같은 방식으로 따로 만들어졌다. 각 클래스에 대하여 30개씩 테스트 데이터가 만들어졌으며, 역시 랜덤 함수를 사용하여 [그림 2]의 신호를 만들어내고 AA, PF, RF를 계산하여 만들어졌다. 여러 번의 훈련과 테스트를 통하여 k-fold cross validation에서 90% 이상의 성공률을 보였으며, 테스트 과정에서도 90% 이상의 성능을 보였다. k-fold cross validation과 테스트 성능을 비교했을 때 과적합 (overfitting)은 발생하지 않았음을 확인할 수 있으며 훈련과 테스트 과정이 적절하게 이루어졌음을 확인할 수 있다. 테스트 과정에서 발생한 confusion matrix의 값은 [표 1]과 같다.

표 1. 테스트 결과의 컨퓨전 매트릭스
Table 1. Confusion matrix in test result

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	500												
2		500											
3			473		27								
4		5		495									
5			17		483								
6		5				495							
7		13					487						
8		14						486					
9		13							487				
10		4								496			
11											500		
12		16										484	
13		4											496

3.3.2 분류기 적용

훈련용 컴퓨터에서 생성된 SVM 분류기를 실제 사용하기 위해서는 생체신호 측정 장비에 설치되어 있는 라떼판다로 훈련되어 생성된 모델 파일을 옮겨서 사용한다. 라떼판다에 생성되는 SVM 분류기는 라떼판다보다 성능이 좋은 컴퓨터에서 훈련된 모델 파일을 로드하여 분류기로서 동작하게 된다. 라떼판다에 설치된 프로그램은 다음의 내용을 포함한다. 여기서 file_name은 다른 컴퓨터에서 훈련된 후 라떼판다로 복사된 모델 파일의 이름이다.

```

    real_model = SVM.LoadModel(file_name);

```

모델 파일을 로드한 후 분류기는 종료될 때까지 다음과 같이 새로운 측정 데이터에 대해 다음의 과정을 수행하여 새로운 측정 데이터가 무엇으로 분류되는지를 결정한다. 새로 측정된 생체 신호는 problem에 저장되어 사용되며 다음에서 result는 측정된 생체 신호 problem에 대한 분류 결과이다.

```

    problem = problem.Normalize(SVMNormType.L2);
    // 훈련과 같은 scaling 반드시 필요
    result = SVM.Predict(real_model,
    problem.X[0]).ToString();

```

역시 훈련 데이터를 사용하여 확인한 결과 90% 이상의 성능을 보였다.

3.3.3 분류기 개선

SVM 분류기의 성능은 훈련 데이터에 의해 결정된다. SVM 분류기의 성능이 장비에서 원하는 만족 기준에 미치지 못한다면 측정 장비는 사용되면서 계속 새로운 데이터를 장비에 저장하므로 새로 저장된 데이터는 SVM 분류기의 성능을 개선하기 위하여 새로운 훈련 데이터로 사용될 수 있다. 새로 생성된 훈련 데이터를 사용하여 SVM 분류기의 모델 파일을 훈련을 통하여 생성하고, 분류기의 모델 파일을 새로 로드함으로써 분류기를 지속적으로 계속 개선할 수 있다. 측정 장비에 포함되어 있는 분류기의 정확도는 측정 장비에 저장된 데이터의 품질에 따라 달라지므로 본 측정 장비는 주기적으로 각 개별 측정 장비의 데이터를 중앙에 있는 서버로 전송하고, 중앙 서버에서는 각 측정 장비에서 전송된 데이터를 정리, 활용하여 새로운 데이터로 머신러닝을 진행하여 분류기를 새로 만든다. 새로 만들어진 분류기는 다시 각 측정 장비로 전송되어 각 측정 장비의 분류기를 업데이트하여 판단 기능을 향상 시킨다. 따라서 각 측정 장비의 생체 신호 분석 분류기의 정확도는 측정 장비를 사용할수록 지속적으로 그 성능이 향상되는 장점을 가지고 있다. 그림으로 설명하면 다음의 [그림 4]의 과정을 반복하면서 측정 장비의 분류기 성능을 지속적으로 개선한다.




그림 5. 주기적으로 분류기 재생성 후 업그레이드

Fig. 5 Periodically upgrading devices after creating new classification module

IV. 결론

피부 저항을 이용한 생체 신호는 스트레스성 질환에 따라 다른 특성을 보이고 있으므로 신호의 특성에 따라 어떤 종류의 스트레스성 질환의 가능성이 높은지를 정확히 해석하는 능력이 필요하다. 하지만 그 분야의 전문가가 아니면 측정 신호의 특성에 따라 측정 대상자를 미리 정의된 질환의 적절한 클래스로 정확히 분류하는 것은 매우 어렵다.

머신러닝을 이용한 입력 데이터의 분류 기법은 다양한 분야에 적용되고 있다. 본 연구에서는 라떼판다와 같은 제한적인 컴퓨팅 성능 환경에서도 실행 가능한 SVM을 사용하였다. SVM의 판단 모델은 훈련 데이터의 일부분인 지지벡터(support vector)만 유지하면 되는 기법이지만 실험실에서 실제 상황을 가정하여 랜덤하게 생성된 측정 신호로 그 정확도를 판단한 결과 90% 이상의 정확도를 보였다. 생성된 모델은 본 연구에서 사용하는 라떼판다와 같이 제한적인 성능을 보이는 측정 장비에서도 지지벡터만 유지하면 되므로 매우 효과적인 방식으로 예측하였으며, 생성된 판단 모델의 크기를 확인한 결과 실제 지지 벡터의 크기가 훈련 데이터의 1/10 이하임에도 측정 신호에 대하여 즉각적인 판단 결과를 보이는 것을 확인 하였다. 본 연구에서 사용한 분류기의 신뢰성은 개발된 장비를 사용하면서 지속적으로 임상 데이터가 축적되면 재훈련 과정을 거치면서 계속 높아질 것이다.

본 논문은 중소기업청에서 지원하는 2017년도 산학연협력 기술개발사업(No. C0512009)의 연구 수행으로 인한 결과물임을 밝힙니다.


References

- [1] B. Song, "Clinical application of 7 zone diagnostic system," *J. of Korean Acupuncture*, vol. 23, no. 3, Mar. 2006, pp. 231-239.
- [2] Y. Kim, H. Lee, and K. Lee, "Design and Implementation of IoT based Urination Management System," *J. of the Korea Institute of Electronic Communication Science*, vol. 12, no. 1,

Feb. 2017, pp. 209-218.

- [3] Y. Oh, "An Analysis System Using Big Data based Real Time Monitoring of Vital Sign: Focused on Measuring Baseball Defense Ability," *J. of the Korea Institute of Electronic Communication Science*, vol. 13, no. 1, Feb. 2018, pp. 221-228.
- [4] D. Kim and Y. Han, "Sensitivity illumination system using biological signal," *J. of the Korea Institute of Electronic Communication Science*, vol. 9, no. 4, Apr. 2014, pp. 499-507.
- [5] J. Yoo, "Analysis of Factor AA in 7-section Diagnosis System and Correlation with Clinical Indicators," *J. of Korean Acupuncture*, vol. 24, no. 6, July 2007, pp. 159-170.
- [6] S. Yoon, "Personal Biometric Identification based on ECG Features," *J. of the Korea Institute of Electronic Communication Science*, vol. 10, no. 4, Apr. 2015, pp. 521-526.
- [7] P. Harrington, *Machine learning in action*. Shelter Island, NY: Manning Publication, 2013.
- [8] B. Boser, I. Guyon, and V. Vapnik, "A training algorithm for optimal margin classifier," In *Proc. the Fifth Annual Workshop on Computational Learning Theory*, ACM Press, Pittsburgh, PA, USA, July 27-29, 1992, pp. 144-152.
- [9] J. Kim, O. Lee, and Y. Ko, "Implementation of Medical Care System based on Home Network," *J. of the Korea Institute of Electronic Communication Science*, vol. 6, no. 6, Dec. 2011, pp. 987-991.
- [10] C. Chang and C. Lin, "LIBSVM: a library for support vector machine," *ACM Trans. Intelligent Systems and Technology*, vol. 2, no 3. Apr, 2011, Article 27, pp 27:1-27:26.

저자소개



홍동권(Dong-Kwon Hong)

1985년 8월 경북대학교 졸업 (공학사)

1992년 8월 U. of Florida. 졸업(공학석사)

1995년 12월 U. of Florida 졸업(공학박사)

계명대학교 컴퓨터공학과 교수

※ 관심분야 : 머신 러닝



채용웅(Yong-Yoong Chai)

1985년 8월 서강대학교 졸업(공학사)

1991년 4월 Oklahoma State Univ. 졸업(공학석사)

1994년 12월 Oklahoma State Univ. 졸업(공학박사)

계명대학교 전자공학과 교수

※ 관심분야 : DC-DC컨버터

