

생체신호를 이용한 감정상태  
검출 알고리즘에 대한 연구

연세대학교 대학원  
생체공학협동과정  
전기전자공학전공  
이 충 기

생체신호를 이용한 감정상태  
검출 알고리즘에 대한 연구

지도 유 선 국 교수

이 논문을 석사 학위논문으로 제출함

2006년 6월 일

연세대학교 대학원

생체공학협동과정

전기전자공학전공

이 충 기

이충기의 석사 학위논문을 인준함

심사위원 \_\_\_\_\_ 인

심사위원 \_\_\_\_\_ 인

심사위원 \_\_\_\_\_ 인

연세대학교 대학원

2006년 6월 일

## 감사의 글

허우대만 멀쩡하고 어리숙했던 24살, 연구실 문을 두드리고 지도교수님을 처음 찾아뵈었을 때가 생각납니다. 2년 전 석사과정을 시작했던 설렘과 두려움이 지금도 눈에 환합니다. 이제 이 논문을 끝으로 석사과정의 마침표를 찍으면서 제게 힘이 되어준 분들께 감사의 마음을 전합니다.

가장 먼저 저를 받아주시고 열정적인 가르침으로 공학자의 길을 걷게 해주신 유선국 교수님께 깊은 감사드립니다. 항상 건강하시고 앞으로 박사과정 때에도 많은 가르침 부탁드립니다. 그리고 깊은 헤아림으로 격려해주시는 김남현 교수님, 졸업논문 심사에 심혈을 기울여주신 생리학교실 이배환 교수님께 감사드립니다. 또한 자주 찾아뵈진 못했지만 제 인사를 따뜻하게 받아주시며 격려를 아끼지 않으신 김덕원 교수님, 서활 교수님, 박종철 교수님, 박시내 교수님께 감사드립니다.

응원단 시절부터 항상 많이 도와주시고 격려해주신 손홍규 부총장님께 감사드립니다. 그리고 개인식별연구소에 처음 자리 잡았을 때부터 지금까지 찾아뵈릴 때 마다 반갑게 맞아주시고 신경써주시는 치과대학 김기덕 교수님, 정호걸 교수님께 감사드립니다. 또한 강력한 카리스마와 리더십을 손수 보여주신 구장내과 최종훈 교수님, 이동주 교수님께 감사드립니다.

생체인식에 대하여 많은 도움을 주신 Toh Kar-Ann 교수님께 감사드립니다. 그리고 제가 이 자리에 있을 수 있도록 힘써주신 명지대학교 강경식 교수님, 백승화 교수님께 감사드립니다. 생리학적 지식을 자세히 짚어주시며 인간적인 가르침을 주신 서울대학교 류관동 교수님께 감사드립니다. 또한 프로젝트와 논문에 많은 도움을 주신 경상대학교 이건기 교수님, 용인송담대학 이병채 교수님, 정기삼 교수님, 청주대학교 김동준 교수님께 감사드립니다. 앞으로도 많은 가르침과 도움 주십시오.

연구실에서 힘들 때 상담을 해주시고 큰 힘이 되어주신 석명형, 동근형, 순만형 감사드립니다. 또 같이 졸업하는 연구생 재홍형, 진호, 수정 그 동안 고맙습니다. 현재 연구실에서 같이 동고동락하는 기원형, 민규형, 정진, 동현, 윤정, 덕찬, 국진

형, 영재, 정채, 유진누나, 헤미누나 모두에게 감사의 말을 전합니다. 지금은 졸업생이지만 옛날 마음을 나누었던 하영, 병수형, 준형, 호현형, 영일형, 혜정누나, 경하형, 계동형 모두 감사합니다. 의학교실에서도 같이 공부하는 생체계측 연구실 여러분, 지금은 연구 강사로 활동 중이신 아람누나, 밝은 웃음으로 반겨주시는 지영누나, 선영누나, 혜정누나에게도 감사의 말을 전합니다.

대학입학부터 운명적인 만남으로 지금껏 친형제처럼 지내는 연세대학교 응원단 선후배, 동기 분들께 감사의 말을 전합니다. 특히 재훈형, 로권형, 윤철형, 명화형, 상훈형, 형구형, 선종형, 우진형, 상욱형, 민규형, 준혁형, 형훈, 준희, 민선, 동혁, 균파, 순욱, 상아, 은미, 혜선 모두 감사합니다. 그리고 아끼는 01, 02, 03, 04, 05, 06학번 후배들에게 고맙다는 말을 전합니다. 앞으로도 지속적인 발전과 영광적인 승리로 연고전을 필승으로 이끌어 주길 바란다.

마지막으로 무조건적인 사랑으로 처음부터 끝까지 저를 완성시켜주신 부모님! 너무 너무 사랑하고 존경합니다. 말로 표현할 수 없을 만큼 감사드립니다. 더욱 당당하고 자랑스런 아들이 되겠습니다. 그리고 지금은 독일에 있어 아쉽지만, 세계적으로 아름다운 목소리를 가진 우리 누님! 동생을 매일 생각해주고 잘해줘서 너무 고맙고 한국을 빛내주길 바랍니다. 이 논문을 마무리 짓는 지금 이 순간 까지 노력했던 땀과 눈물을 흘리면서 견뎌낼 수 있었던 것은 사랑하는 가족의 힘이 있었기 때문입니다. 이 책 한권을 사랑하는 가족에게 바칩니다.

2006년 7월

이 충 기 드림

# 차 례

그림 차례	iii
표 차례	iv
국문 요약	v
제1장 서론	1
제2장 실험장비 및 프로토콜 설계	5
제3장 생체신호 처리 및 특징 추출	9
3.1 심전도 처리 기술	9
3.2 피부 전도도 처리 기술	19
3.3 피부 온도 신호 처리 기술	22
3.4 데이터 정규화	23
3.5 생체신호처리의 전체 시스템 구조	24
제4장 패턴인식 알고리즘을 이용한 감정인식	25
4.1 선형판별함수	25
4.2 Reduced Multivariate Polynomial Model	26
4.3 신경회로망	32
4.4 Support Vector Machine	43
제5장 결과	52
5.1 SAM을 이용한 실험자 주관평가 결과	52
5.2 감정상태에 따른 통계적 유의성 평가	53
5.3 패턴인식 알고리즘을 이용한 감정상태 검출 정확성 평가	54
5.3.1 선형분별함수	54
5.3.2 Reduced Model평가	55
5.3.3 신경회로망	57

5.3.4 RBF kernel을 이용한 SVM 평가	58
5.3.5 4가지 알고리즘에 대한 전체적인 성능평가	59
5.3.6 파라미터 선택에 의한 4가지 알고리즘 정확도 평가	61
제6장 결론	64
영문 요약	69

## 그 립 차 례

그림 1.	감정의 이원적 분류 이산적 분포 . . . . .	2
그림 2-1.	실험에 사용된 패/불패 동영상 프로토콜 . . . . .	6
그림 2-2.	실험에 사용된 자기설문평가지(SAM) . . . . .	6
그림 2-3.	감정유발 실험 시 생체신호 측정 부위 . . . . .	7
그림 3-1.	심전도 신호를 통한 감정데이터 추출과정 . . . . .	9
그림 3-2.	심전도 신호를 이용해 RR 간격을 얻기 위한 QRS 검출과정 . . . . .	10
그림 3-3.	RR 간격 신호의 저주파제거 결과 . . . . .	14
그림 3-4.	비선형 저주파 제거를 이용한 주성분 분석결과 . . . . .	17
그림 3-5.	저주파 제거를 하지 않은 주성분 분석결과 . . . . .	17
그림 3-6.	선형 저주파 제거를 이용한 주성분 분석 결과 . . . . .	18
그림 3-7.	영교차율을 이용한 피부전도도 특징 값 검출(실험자 1) . . . . .	20
그림 3-8.	영교차율을 이용한 피부전도도 특징 값 검출(실험자 2) . . . . .	20
그림 3-9.	감정유발에 따른 실험자의 평균 피부온도 변화 . . . . .	22
그림 3-10.	감정 검출 알고리즘의 전체 시스템 구성도 . . . . .	24
그림 4-1.	입력의 order와 dimension에 따른 수식의 규모 . . . . .	30
그림 4-2.	sinc 함수 추정 (a) 9차 Multinomial - 1 (b) 9차 Multinomial - 2 (c) 9차 RM (d) 9차 MP . . . . .	31
그림 4-3.	신경회로망의 기초적인 구조와 전달과정 . . . . .	33
그림 4-4.	순방향 신경회로망의 모델 . . . . .	37
그림 4-5.	선형 SVM의 최대 마진 분류 평면 . . . . .	45
그림 4-6.	$\xi_i$ 를 이용한 비선형 SVM 최대 마진 분류 평면 . . . . .	49
그림 4-7.	커널함수를 이용한 입력공간에서 특징 공간으로의 변형방법 . . . . .	50
그림 5-1.	Order에 따른 Reduced Model을 이용한 정확도 평가 (5 feature 6 feature) . . . . .	56
그림 5-2.	두 개의 feature set에 따른 각 알고리즘의 평균적 성능평가 . . . . .	59
그림 5-3.	파라미터의 선택적 조합에 따른 4가지 알고리즘 정확도 성능평가 결과 . . . . .	62



## 표 차 례

표 2.	실험 프로토콜 설계 및 기대반응 . . . . .	5
표 5-1.	주관적으로 평가된 SAM 평가결과와 평가에 의한 감정상태 . . . . .	52
표 5-2.	각 feature값에 따른 통계적 검증 (P value = 0.05) . . . . .	53
표 5-3.	선형분별함수를 이용한 정확도 평가 . . . . .	54
표 5-4.	Order에 따른 Reduced Model을 이용한 정확도 평가 (5 feature) . . . . .	55
표 5-5.	Order에 따른 Reduced Model을 이용한 정확도 평가 (6 feature) . . . . .	55
표 5-6.	신경회로망을 이용한 정확도 평가 (5 feature, 6 feature) . . . . .	57
표 5-7.	SVM을 이용한 정확도 평가 (5 feature, 6 feature) . . . . .	58
표 5-8.	두 개의 feature set에 따른 각 알고리즘의 평균적인 성능평가 . . . . .	59
표 5-9.	파라미터의 선택적 조합에 따른 4가지 알고리즘 정확도 성능평가 결과 . . . . .	61

## 국 문 요 약

### 생체신호를 이용한 감정상태 검출 알고리즘에 대한 연구

본 논문의 목적은 생체신호를 이용해 인간의 감정상태를 추정하는 것이다. 인간의 감정상태 추정을 위해 최적의 감정데이터 추출, 생체 파라미터 조합, 정확도와 계산 복잡도의 trade off등이 본 연구에서 다루고 있는 부분이다. 감정은 연속적이고 순간적으로 변화하기도하며 지속적인 감정상태를 나타내기도 한다. 연구의 목적은 순간적인 감정의 변화를 검출하는 것이고 인간의 감정을 다음과 같이 정의했다. 순간적인 감정상태를 측정하고 추정하기 위해 우선적으로 인간의 감정을 이원적인 두 가지 형태(쾌/불쾌)로 나누었다. 남성 19 여성 6명을 대상으로 감정유발 실험을 진행 했으며 감정유발에 대한 자기설문평가(SAM)을 실시했다. Lang에 의해 고안된 SAM평가는 실험자에게 얻어진 데이터가 정말 감정이 유발된 데이터인지 아닌지에 대한 판단기준으로 작용했으며, 자극에 대한 반응정도에 대한 기준으로 작용되어 감성자극 실험에 유용한 설문지로 사용되었다. 인간의 감정상태를 정량적인 데이터로 나타내기 위해 3가지 생체신호 데이터를 측정 (ECG, GSR, SKT) 했다. 위 3가지 데이터는 비교적 측정하는 조건이 까다롭지 않았기 때문에 실험자가 측정 시 불편함을 거의 느끼지 못했다. 감정 유발되어 측정된 생체신호는 신호처리 과정과 패턴인식 과정을 거치게 된다. 우리는 순간적인 감정상태변화를 정확하게 검출하는데 목적이 있기 때문에 전처리 과정으로 생체신호 특징을 추출했고 여러 가지 다양한 패턴인식 알고리즘을 평가함으로써 감정추정에 높은 성능을 나타내는 알고리즘을 구성할 수 있었다.

본 연구에서는 생체신호만을 이용해서 인간의 감정상태를 높은 정확도로 추정할 수 있었으며 사용된 각 파라미터는 손쉽게 측정 가능했고, 그 결과로서 간단한 생체신호의 측정만으로 인간의 감정상태를 정확히 추정함으로써 반응 형 유비쿼터스 서비스를 제공하는 핵심 기술로 활용 가능성을 말해주고 있다.

---

핵심되는 말 : 감정상태 검출, 생체신호(ECG, GSR, SKT)측정, 알고리즘 성능평가

## 제 1 장 서 론

생체신호를 이용해서 감정 상태를 검출하는 것은 인간의 모든 감정 상태가 생체신호로 나타내지고, 역으로 생체신호만을 이용해서 감정상태를 구분할 수 있다는 것이다. 생체신호의 종류는 심전도 (ECG: electrocardiogram), 뇌전도 (EEG: electroencephalogram), 근전도 (EMG: electromyogram), 피부전도도 (GSR: galvanic skin response), 피부온도 (SKT: skin temperature), 맥파(PPG: photoplethysmography)등이 있다. 근전도를 제외한 소개한 모든 생체신호는 자율신경계에 지배를 받고 있으며, 감정상태의 변화에 따라 생체신호의 변화가 발생한다. 자율신경계와 감정 상태에 대한 연구의 시초는 한 세기 전 William James(1884)이 인간의 감성과 자율신경계(ANS: autonomic nervous system)의 패턴에 대한 연구를 내놓으면서 아직까지도 흥미로운 과제로 남아있다.

감성이 인체의 생리적인 상태에 미친다는 사실이 알려진 이후, 사람의 감정상태를 생리신호로부터 추출하려는 많은 시도가 있어왔다. 그러나 이러한 시도에는 몇 가지 문제가 있다. 첫째는 인간의 감성이 매우 다양하고, 사람마다 개인적인 편차가 크다는 사실이다.

Wilhelm wundt는 인간의 감성을 쾌/불쾌(pleasantness/unpleasantness), 긴장/이완(tension/release), 흥분/안정(excitement/relaxation)과 같이 3가지 상반된 영역으로 분류하였다[27] Robert Plutchik은 그림과 같이 분노-공포, 기쁨-슬픔, 수용-혐오, 놀람-예상의 8가지의 큰 틀을 가지고 세분화된 인간의 감성을 표현하고자 하였다. Wundt와 Plutchik의 감성분류의 예에서도 알 수 있듯이 큰 차이는 아니지만 아직도 인간의 감성분류에는 서로 이견이 존재한다. 따라서 생체신호를 가지고 인간의 감성을 분류하려는 시도는 ‘어떻게(how)’라는 방법론적인 문제 이전에 ‘무엇을(what)’이라는 근원적인 문제에 봉착하게 되는 것이다. 즉, 어떤 감성을 어느 정도까지 세분화하여 추출하는가 하는 문제가 우선 선결되어야 한다.

두 번째 문제점은 사람마다 경험과 지식이 다양할 뿐만 아니라 개인적인 감성의 종류와 그 반응 또한 매우 다양하여 일반화가 불가능하다는 것이다. 즉, 특정한 상황에서 어떤 사람은 매우 큰 반응을 보이지만 그러한 상황을 반복적으로 경험한 사람이거나 상황에 관심이 없는 사람은 별다른 반응을 보이지 않는다. 따라서 생체신호의 반응도 특별한 변화가 없을 수 있다. 대부분의 연구가 실험실 상황에서 특정한 감성을 유발하는 자극을 주고 안정 또는 상반된 감성유발 상태와 비교하여 분석하여 왔다. Levenson 등은 감성상태에 따른 자율신경계의 반응을 관찰한 결과 긍정적인 감정(행복감)에서의 심박수나 피부저항이 부정적 감정(분노, 공포)에서 보다 낮게 나타났다는 보고를 했다.[7] 그러나 이러한 연구 결과들은 특정 상태에서의 생리적 신호 중에서 일부 특성이 비교 상태와 통계적으로 유의할 만한 차이를 나타낸다는 사실만을 보고 할뿐, 슬픔과 같은 감성 상태를 판별할 수 있는 생체 신호의 절대적인 특성 또는 기준은 제시하고 있지 못하고 있다.

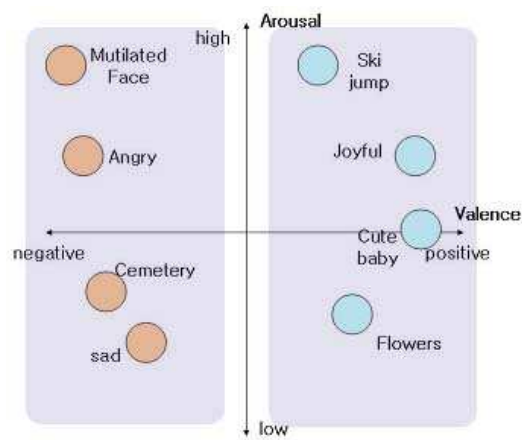


그림 1. 감정의 이원적 분류와 이산적분포  
(Valence-Arousal 평면)

감정은 물질적 요소와 인지적 요소의 복잡한 결합으로 정의 하는데 대부분의 감정에 관한 문헌들이 이를 동의하고 있다. 물질적 요소는 생리적 변화로 유발되는

신체적인 상태를 의미하는 반면 인지적 요소는 순수 정신적 감정상태만을 의미한다.[3] 물질적 요소는 육체적인 활동을 의미하며 생리학적인 시스템의 활동으로 정의되고 있으며 교감신경과 부교감신경의 활동으로 정량화 할 수 있다. 물질적 감정에 대한 해석은 생리적으로 흥분상태와 안정상태로 나누고 감정을 평가할 때 감정상태에 대한 분류를 단순 이원화 시켜 해석한다. 그러나 복잡한 감정상태를 물질적 해석만을 가지고 평가 하는 것은 무리가 있다. 그래서 인지적 요소와 함께 고려한 감정의 해석은 크게 긍정적인(Positive) 쾌 감정과 부정적인(Negative) 불쾌 감정으로 분류 된다. 두 분류의 감정은 절대적인 기준으로 분류할 수 없으며 상대적인 판단 기준으로 감정을 나눌 수 있다. 하지만 상대적인 만족도가 긍정적인 감정과 일치하지 않고 주관적인 평가를 통해 정성적인 해석이 가능할 뿐 감정에 대한 정량적인 해석은 불가능하다. Lang의 감정구성에 관한 연구에 따르면 다차원의 공간상에서 감정의 속성을 정의했다. 감정을 구조적 측면 바라본 개념 중 가장 널리 쓰이고 있는 것은 그림 1 에서 나타난 2차원 Valence-Arousal 평면이다. Valence는 긍정(Positive)과 부정(Negative)에 관한 감정의 정도를 나타낸 척도이고 Arousal은 평온(Calm)과 흥분(Excited)의 정도를 나타내는 척도이다. 그림 1 에서 나타나는 이산 적(discrete)으로 분리되어 있는 모든 감정의 속성을 구분하는 것은 무리가 있다 판단하고 그림 1 의 음영부분을 감정 식별의 대상으로 설정하고 연구할 것이다. 구체적으로 말해서 물질적으로 안정된 상태에서 두 가지 감정상태(쾌/불쾌)로 유발된 데이터를 생리학적으로 해석하고, 역으로 적절한 신호처리 과정과 패턴인식 과정을 적용하여 감정을 추정하려고 한다.

세 번째 문제점은 생체신호는 신호의 종류 및 장비에 따라 실제 생활환경에서 측정이 매우 어렵다는 사실이다. 실험실 환경에서 감성의 유발은 그 자체가 피검자에게 매우 부자연스러운 스트레스가 될 수 있고 특히 어린이의 경우에는 전극부착 조작 하나의 공포/불안을 유발하는 자극이 될 수 있다는 사실이다. 또한 뇌전도, 심전도 등과 같이 많은 전극의 부착을 요구하는 실험의 경우 실험 시간과 공간의 제약을 많이 받을 수 있다.

본 연구는 인간의 감성상태에 따라 변화되는 생체신호를 검출하고 역으로 생체신호만으로 인간의 감성상태를 검출해내는 알고리즘을 설계하는 것이다. 이러한 목표를 달성하기 위해서 기술적인 문제 이외에도 몇 가지 현실적인 제한이 존재한다. 첫째는, 본 연구는 동영상(video clips)을 이용해 감성상태를 유발하기 때문에 동영상 선정과 동영상에 대한 평가(self evaluation)가 실험 성공의 가장 큰 요인으로 작용될 것이다. 그렇기 때문에 실험에 사용되는 동영상은 모든 실험자에게 감성적인 변화를 충분히 유발할 수 있는 동영상을 만들어야 한다. 두 번째는 신뢰성 있는 생체신호처리(biosignal processing)를 해야 한다. 알고리즘은 감성 상태에 따른 신호의 차이를 가급적이면 구분 가능한 값으로 변화해야한다. 셋째는 감성상태를 추출할 때 가정 최적의 패턴인식(Pattern Recognition) 알고리즘의 선정문제다. 가급적이면 정확도(Accuracy)는 높은 것을 기본으로 계산하기 간결한 알고리즘의 형태로 컴퓨터의 부하(Computational Complex)를 주지 않는 알고리즘을 선정해야한다. 마지막으로 유비쿼터스 서비스와 HCI의 개념과 맞물려 인간을 감성상태를 두 연구에 응용, 적용해볼 때 인간의 감성상태를 대변할 수 있는 비 침습적인(non\_invasive) 생체신호 파라미터(parameter) 선정에 대한 연구를 해야 한다.

본 논문의 구성은 2장에서 실험장비 및 프로토콜 설계에 대해 설명하고 3장에서는 생체신호처리 및 특징 추출에 알고리즘에 대해서 제안하였다. 4장에서는 패턴인식 알고리즘을 이용한 감정인식에 대해 다루면서 본 연구에서 사용한 선형분별함수(Linear Discrimination Function), Reduced Multivariate Polynomials Model, 신경회로망(neural network)이나 SVM(support vector machine)에 대해 소개하고 있다. 그리고 5장은 실험 결과를 나타내 주고 있으며 마지막으로 6장은 각 단계별로 제안된 알고리즘과 통합된 시스템에 대해서 요약하고 앞으로의 발전방향에 대하여 논의함으로써 글을 맺는다.

## 제 2 장 실험 장비 및 프로토콜 설계

건강한 실험자 성인 남녀 25명(남자 19, 여자 6)을 각각 3번씩 감정유발 실험을 진행했다. 실험자의 연령은 21~29 이고 평균나이는  $25 \pm 4$  이다. 실험 전 흡연, 약물복용, 질병(감기), 알코올, 수면시간에 대한 설문을 실시했으며, Tilt\_Table(Bed)을 이용해 누운 편안한 자세로 실험을 진행했다. 그리고 실험 중 실험자에게 움직임은 자제하도록 권유했다. 실험환경은 Severance Hospital에 마련된 3평 정도의 최적한 방에서 이루어졌으며 실험자는 감정유발 실험에 앞서 15분 정도 휴식 시간을 가졌다. 실험과정은 표 2에서 보여주고 있다. 감정 유발영상은 빔 프로젝터를 이용해 40inch 스크린에 보여주었다. 그림 2-1 에서 보여주는 것과 같이 자극의 종류는 쾌(긍정)와 불쾌(부정)로 나눌 수 있으며 긍정적인 감정을 유도하는 영상은 녹화된 variety 오락프로그램을 동영상으로 보여주었고 부정적인 감정을 유도하는 영상은 국립과학수사연구소에서 얻은 “살인 및 자살 사진”을 동영상으로 편집하여 보여주었다. 두 감정을 유도하는 시간은 각각 10분으로 모든 실험자에게 동일한 시간 동안 자극을 주었다. 긍정유발과 부정유발에서 우리가 원하는 반응은 육체적 흥분에 관계없이 정신적인 쾌/불쾌를 유발하는데 있다.

표 2 실험 프로토콜 설계 및 기대 반응

감정유발	시간 (분)	실험 영상	감정 유발 영상	기대되는 반응	
				Arousal	Valence
쾌 유발 (positive)	10	Variety Show	Happiness, Uplifting	상관하지 않음 Don't care	매우 쾌 very positive
불쾌 유발 (negative)	10	murder, suicide, trauma patient	Passive, Anger, Want to Avoid	상관하지 않음 Don't care	매우 불쾌 very negative



그림 2-1 실험에 사용된 쾌/불쾌 동영상 프로토콜

각 실험자는 2~3번 이상 실험을 해주었는데 감정유발에 이용된 영상은 각각 다른 영상이다. 감정유발 자극이 이루어진 후 Lang에 의해 고안된 SAM을 이용해서 자극에 대한 자기설문평가(Self Estimation)를 실시했다.[3]

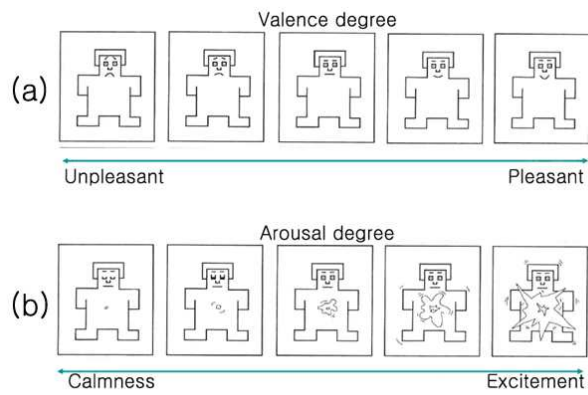


그림 2-2 실험에 사용된 자기 설문 평가지(SAM)

(a) valence 정도 평가

(b) arousal 정도 평가



실험자에게 감정유발 동영상을 보여준 후 시각자극에 대한 실험자의 심리지수를 평가하기 위하여 주관적 평가 방법인 SAM(Self-Assessment Manikin)을 사용하였다. SAM은 다양한 자극에 대한 실험자의 감성적 반응을 심리적으로 알아보기 위한 방법으로 많이 쓰이고 있다. SAM은 언어를 사용하지 않고 그림으로 되어 있으므로 비 문자 사용계층까지 널리 사용할 수 있다는 장점이 있다. SAM은 감정을 나타내는 행복-불행 척도를 그림 2-2 와 같이 나타냈으며 각 척도들은 5단계로 되어 있다.




그림 2-3 감정유발 실험 시 생체신호 측정 부위  
(심전도, 피부전도도, 피부온도)

생체신호를 측정하기 위해 Biopac MP150을 이용했다. 여러 가지 생체신호 중 가급적이면 측정하는 생체신호의 종류를 줄이고, 가급적이면 감정상태를 잘 나타낼 수 있도록 했다. 그림 2-3에서 보여지는 것과 같이 양팔과 오른다리 발목에 심전도를 측정했고 왼손 검지와 중지에 피부전도도를 측정했으며, 목 부위에 피부온도를 측정했다. 각 신호는 1000Hz, 250Hz, 250Hz로 샘플링 되었다. 심전도는 자율신경계의 교감신경, 부교감 신경의 활동을 모두 나타낼 수 있으며, 피부전도도는 감정상태가 흥분되었을 때 손가락 끝의 모세혈관이 팽창하여 땀샘에 땀이 분비된다. 그러면 피부의 전기 전도도는 높아지게 된다. 피부 전도도는 자율신경계의 교감신경 부교감 신경의 활동 중 오직 교감신경에만 영향을 받는 신호이고 매우 민

감한 신호다. 피부온도 역시 인간의 감정상태를 대변 할 수 있는 요소로 가정하고 자율신경계의 영향을 받는 신호다. 대부분의 문헌에 의하면 피부 온도는 피부 전도도와 같이 손가락 끝에서 측정을 하지만, 본 연구에서는 실험자의 손가락 끝에서 측정했을 때, 감정에 상관없이 손가락의 온도가 너무 찬 실험자와 손가락 온도가 정상적인 사람간의 차이가 너무 심했기 때문에 손가락을 제외한 피부온도를 측정하는 위치를 찾게 되었다. 인간의 감정상태에 따른 피부온도 변화를 반영할 수 있으며, 비교적 실험자간의 차이를 덜 갖는 부위를 찾은 결과 목에서 측정하는 것으로 정했다. Petal 의 연구에 따르면 인간의 감정상태중 당황하거나 부정적일 때 얼굴, 목, 귀의 온도가 올라간다고 밝힌바 있다.[30] 그리고 유비쿼터스 웨어러블 컴퓨팅(ubiquitous wearable computing device)환경에서 비 침습적이며 무구속적인 측정을 위해 두 팔의 자유를 주기 위해 목에서 피부온도를 측정했다.

### 제 3 장 생체신호 처리 및 특징 추출

본 장에서는 데이터 측정 장치에서 얻어낸 생체신호를 감정을 대변할 수 있는 값의 형태로 만들어주는 전처리(preprocessing) 단계를 나타내 주고 있다. 생체 신호 처리 단계에는 심전도에는 재 샘플링(resampling), 잡음 필터링(noise filtering), QRS 검출(QRS detection), 저주파제거(detrending), 30초 간격으로 분할(fragmentation), 주성분 분석(PCA: principle component analysis) 계산, 심박동수(mean heart rate) 계산, RR 간격(RR interval)의 분산값(variance of RR interval) 계산이 있다.

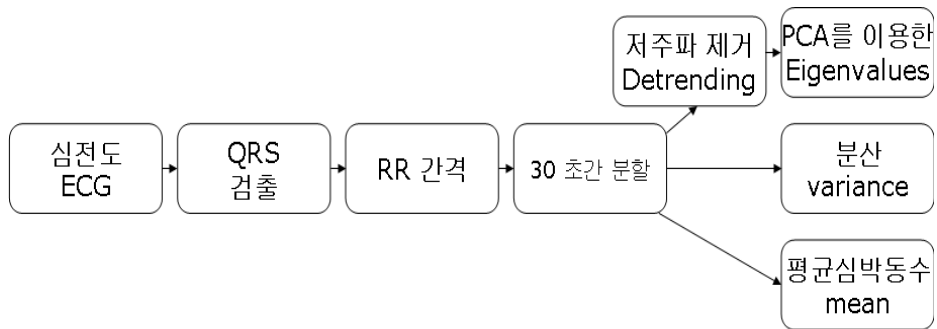


그림 3-1 심전도 신호를 통한 감정데이터 추출 과정

#### 3.1 심전도 신호처리 과정

심전도는 자율신경계의 활성정도를 정량적으로 평가하는데 사용된다. 자율신경계는 감정상태를 대변한다고 가정하기 때문에 심전도 신호를 이용해서 어떻게 하면 감정상태를 가장 잘 반영하는 특징 데이터를 추출 할 수 있는지에 대한 연구는 아직까지 절대적으로 권고되는 연구는 없다. 본 연구에서는 심전도 신호에 감정상태를 가장 잘 반영시키는 특징을 추출하기 위해 여러 가지 방법을 적용해 보았다. 그림 3-1 은 본 논문에서 사용된 심전도에서 감정상태를 나타낼 수 있는 특징을 추출하는 과정을 보여주고 있다. 가공되지 않는 심전도를 QRS검출 알고리즘을 통

해 R 점을 검출하고 얻어진 연속적인 R 점들을 시간 축으로 나타낸 것이 RR 간격이다. RR 간격을 매 30초마다 분할을 하고 분할된 구간에 주성분 분석을 통해 첫 번째 고유 값들의 mean, median값, 분산 그리고 평균 심박동수를 계산해 낸다. 그러므로 우리는 심전도 신호를 통해 총 4개의 특징을 추출해낼 수 있다. 주성분 분석을 할 때는 저주파제거 과정을 추가하게 되는데, 30초 간격마다 RR 간격이 가지고 있는 DC값을 제거해줌으로써 심박동의 순간적인 변화를 검출하는데 사용된다. 저주파제거과정과 주성분 분석에 대한 자세한 설명은 다음부분에 설명하도록 하겠다.

### QRS 검출 알고리즘

심전도 신호에서 R 점을 추출하는 알고리즘은 다양한 방법이 제안되어지고 있다.[28] 여러 알고리즘이 제안되고 있지만, 정확도와 계산 량을 trade off 해볼 때 Hamilton 과 Tompkins가 주장하는 알고리즘을 선정했다.[29] 그들의 알고리즘은 99%이상의 R점 검출능력을 보이고 있으며, 계산 량은 다른 알고리즘에 비해 중간 정도의 계산 복잡도 특성을 지니고 있다.




그림 3-2 심전도 신호를 이용해 RR 간격 얻기 위한 QRS 검출 과정

Hamilton & Tompkins의 알고리즘의 구성은 그림 3-2에서 나타내고 있다. 가공되지 않은 심전도를 미분을 통해 심전도 P-Q-R-S-T 신호가 가지고 있는 저주파의 특성 T신호는 약해지도록 만들고 QRS 신호는 강조되도록 한다. 그리고 제곱화를 통해서 QRS 신호를 더욱 강조시킴으로써 미분해서 차이가 큰 QRS 신호는 P

신호에 비해 상대적으로 강조되게 된다. 제곱화 과정을 거치면 여러 개의 극점 (peak)을 가진 신호가 된다. 그 다음 평균필터를 이용해서 제곱 화되어 여러 개의 극점을 가지고 있는 신호를 부드럽게 만들어주고 적절한 문턱치(adaptive thresholding)를 구하게 된다. Hamilton& Tompkins가 주장하는 적절한 문턱치 계산법은 식 (1)에 나타나 있다. QRS검출를 그림으로 설명한 것은 참고문헌에서 많이 다른 내용이기 때문에 생략하도록 하겠다.

$$\begin{aligned}
 SPKI &= 0.125 PEAKI + 0.875 SPKI && \text{단, } PEAKI \text{ 는 신호의 극값} \\
 NPKI &= 0.125 PEAKI + 0.875 NPKI && \text{단, } PEAKI \text{ 는 노이즈의 극값}
 \end{aligned}$$

$$THRESHOLD I 1 = NPKI + 0.25 (SPKI - NPKI) \tag{1}$$

$$THRESHOLD I 2 = 0.5 THRESHOLD I 1$$

$$SPKI \text{ 를 갱신하는 식은 } SPKI = 0.25 PEAKI + 0.75 SPKI$$

### 저주파제거 필터

심전도 신호를 통해 4가지 특징을 추출해 낼 수 있는데, 그 중 2가지는 저주파 제거 과정과 주성분분석을 통과시켜야 나오는 값이다. 심전도에서 얻어진 RR 간격이 순간적인 감정의 변화를 대변할 수 있고, 불쾌 감정상태일 때 자율신경계의 교감신경과 부교감신경이 동시에 활성화되어 심박동 간격의 변이가 증가한다고 가정한다. 불쾌 감정상태일 때 순간적인 심박동의 변화로 신호의 전체적인 에너지의 값에 변화가 발생하고, 그 변화가 DC값의 상승이나 하강으로 나타나는 것을 저주파가 발생한다고 한다. 정해진 구간에 발생된 저주파를 DC값이라 하고, 저주파 DC값을 제거하지 않은 신호의 고유 값(eigenvalue)을 바로 계산하면 특징 추출된 값에 영향을 주기 때문에 저주파 DC값을 제거해주어야 한다. 저주파제거는 RR 간격의 DC 값을 제거해주는 방법으로 선형 저주파 제거(linear detrending method)와 비선형 저주파 제거(nonlinear detrending method)가 있다. 선형 저주파 제거 방법은 신호의 시작점과 신호의 끝점으로 1차 함수( $y=a*x+b$ )의 형태로 만들어주고 원래 RR 간격 신호와 1차함수를 빼주면 함수의 x값에 따라 RR 간격의 저주파 성분이 제거된다. 선형 저주파 제거를 통해 나온 결과는 그림 3-2에 잘 나타나 있다.

비선형 저주파 제거 방법은 Mika P. Tarvainen의 논문에 제안된 방법으로, 그가 제안한 알고리즘을 이용해서 주파수 도메인(frequency domain)에서 RR간격을 나타냈을 때 고주파(high frequency) 성분의 특성을 강조해서 나타낼 수 있었다.[6] 그의 알고리즘을 소개 하자면 RR간격을 식 (2)와 같이 두 가지 성분의 조합으로 모델링을 했다.

$$z = z_{stat} + z_{trend} \quad (2)$$

단,  $z_{stat}$ 는 stationary한 RR 간격이고,  $z_{trend}$ 는 비주기적인 저주파 성분이다. 그리고  $z_{trend}$ 은 식 (3)와 같은 선형 함수로 모델링 되어진다.

$$z_{trend} = H\theta + v \quad (3)$$

단,  $\theta$ 는 회귀 파라미터(regression parameter)이고,  $v$ 는 관측 오류(observation error)이다.  $\hat{z}_{trend} = H\hat{\theta}$ 을 이용해서 저주파를 예측할 수 있고,  $\hat{\theta}$ 는 식 (4)의 방법을 이용한 최소자승법(least square method)으로 구할 수 있다.

$$\hat{\theta}_\lambda = \arg \min \{ \| H\theta - z \|^2 + \lambda^2 \| D_d(H\theta) \|^2 \} \quad (4)$$

식(4)은 라그랑지안(Lagrangian) 방법이다.  $\lambda$ 는 라그랑지안 승수이고  $D_d$ 는 미분을 나타낸다.  $H\theta$ 는 일차 함수고, 미분한  $D_d(H\theta) = 0$ 이다. 식 (4)을 풀어서 다시 쓰면 식 (5)과 같이 나타낼 수 있다.

$$\hat{\theta}_\lambda = (H^T H + \lambda^2 H^T D_d^T D_d H)^{-1} H^T z \quad (5)$$

$$\hat{z}_{trend} = H\hat{\theta}_\lambda \quad (6)$$

단,  $\hat{z}_{trend}$ 는 우리가 제거를 원하는 저주파 성분을 추정한 값이다. 그래서 저주파를 제거한 stationary한 RR 간격 신호는 식 (7)와 같이 추정되어 진다.

$$\hat{z}_{stat} = z - H\hat{\theta}_\lambda = (I - (I + \lambda^2 D_2^T D_2)^{-1})z \quad (7)$$

비선형 저주파 제거 방법을 적용시킨 RR 간격신호는 그림 3-3에 나타나 있다. 그림 3-3을 보면 비선형 저주파 제거 방법이 선형 저주파 제거 방법보다 저주파 제거 성능이 뛰어난을 나타내고 있다.

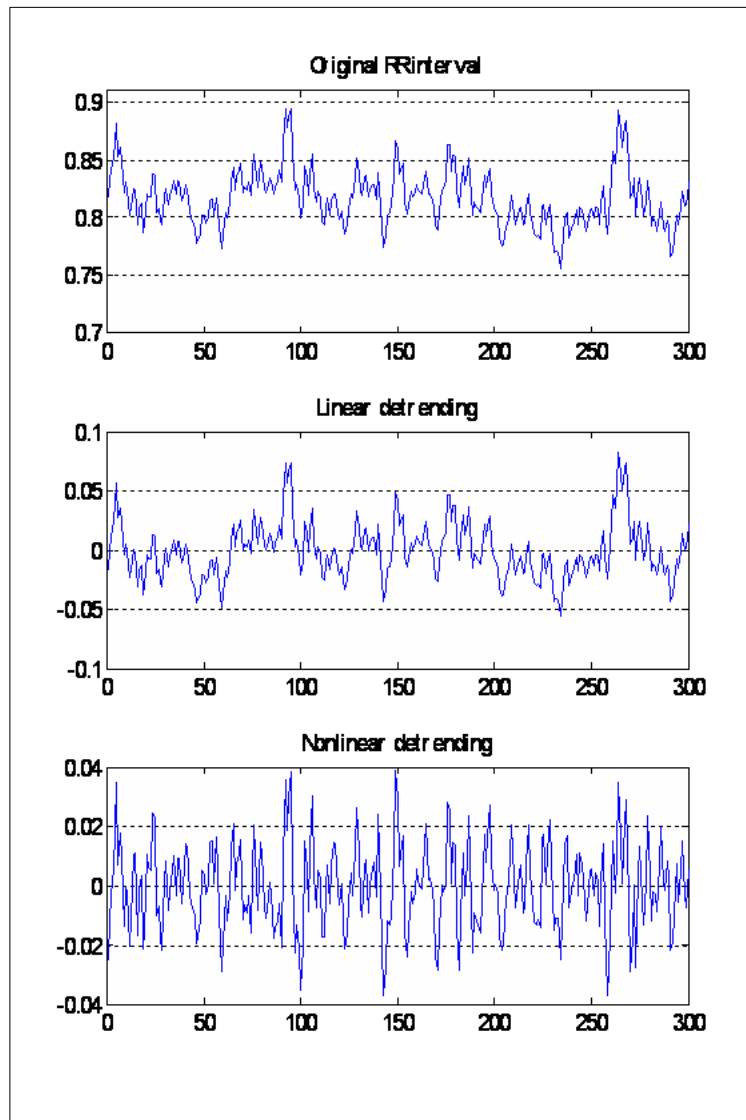


그림 3-3 RR 간격 신호의 저주파제거 결과  
(선형 저주파 제거, 비선형 저주파 제거)



## 주성분 분석

주성분 분석(PCA : Principal Component Analysis) 변환은 신호 처리 분야, 통계학 그리고 신경망 관련 연구에서 주로 쓰인다. 이는 Karhunen-Loeve 변환 또는 Hotelling 변환이라고 불리기도 한다. 주성분 분석 변환이란 고 차원 입력 벡터를 저 차원의 형태로 표현하는 방법인데, 이는 전체 데이터를 가지고 그것들의 분산이 큰 몇 개의 고유 방향에 대한 축으로 선형 투사시켜서 차원을 줄이는 방법을 말한다. 주성분 분석 변환을 통해 입력 벡터의 차원을 감소하는 것은 데이터 분포에 대한 정보는 그대로 유지하지만, 계산상의 부하를 감소하고, 노이즈를 제거하며, 데이터 압축과 같은 효과를 가질 수 있도록 한다. 하지만, 각 집단간의 관계를 고려하지 않고, 전체 데이터의 분산을 최대화 하는 방향으로만 선형 투사하기 때문에 집단간의 겹침이 발생하는 단점을 가진다.

30초간 분할한 RR 간격 데이터를 6개로 나누어 5초간의 RR 간격 6개로 분리시킨다. 다음과 같은 5초간의  $n$  차원의 벡터  $x$ 가 6개 존재할 때,

$$X = [X_1, X_2, X_3, X_4, X_5, X_6] \quad (8)$$

평균 벡터는 식 (9)와 같은데, 이 식에서  $M$ 은 벡터의 개수를 의미한다.

$$m_k = \frac{1}{M} \sum_{k=1}^M X_k, \quad M=6 \quad (9)$$

공분산 행렬(Covariance Matrix)은 식 (10)과 같다.

$$Cov = \sum_{k=1}^M X_k X_k^t - m_k m_k^t \quad (10)$$

식 (8)과 같은 입력 벡터를 식 (9)와 식 (10)에 적용하여 구한 평균 벡터와 공분산 행렬을 가지고 고유 벡터(EigenVector)과 고유 값(EigenValue)를 구할 수 있는데, 고유 값의 크기에 따라 고유 벡터를 재 정렬하면 새로운 행렬 A를 만들 수 있다. 벡터 x는 A를 변환 행렬로 사용하여, 벡터 y로 변환할 수 있는데, 이는 식(11)로 표현할 수 있다.

$$y = A(X - m_k) \quad (11)$$

A와 같은 변환을 PCA 변환이라 하는데, 주성분 분석 변환에 의해 생성된 벡터 y의 평균 값은 0이다.

$$m_k = 0 \quad (12)$$

그리고 y의 공분산 행렬은 식 (13)을 통해서 구할 수 있는데, 벡터 x의 고유 값으로 구성된 대각 행렬임을 알 수 있다.

$$Cov * A = \lambda * A \quad (13)$$

각 6개의 고유 값을 구하고 고유 값 중에 첫 번째 고유 값을 추출한다. 그러면, 6개의 고유 값을 30초마다 얻을 수 있다. 첫 번째 고유 값 6개의 벡터를  $\lambda$ 라고 한다. 6개의 벡터 중 30초 동안의 감정상태를 대변하는 하나의 값으로 나타기 위해서, 식 (14), 식(15)과 같은 방법이 다른 두개의 평균구하는 방법으로 특징을 추출한다.

$$\text{특징1} = \text{mean} (\text{Vector } \lambda) \quad (14)$$

$$\text{특징2} = \text{median} (\text{Vector } \lambda) \quad (15)$$

식 (14)(15)와 같은 방법으로 구한 결과는 그림 3-4 과 같이 나타났다. 그림 3-4은 쾌감정과 불쾌 감정일 때 특징 1, 특징 2의 값이 차이가 나타남을 볼 수 있다. 불쾌상태일 때 상대적으로 특징1, 특징 2의 값이 큼을 알 수 있다.

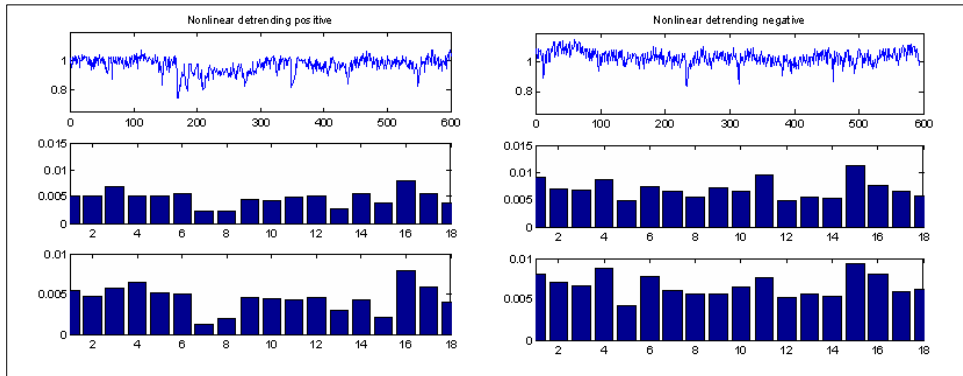


그림 3-4 비선형 저주파 제거를 이용한 주성분 분석 결과  
(특징값 1, 특징값 2)

그림 3-5 는 저주파 제거를 하지 않은 상태에서 주성분 분석을 하고 특징을 추출한 경우이다. 그림에서 보여주는 것과 같이 첫 번째 고유 값들은 신호의 저주파 성분의 DC값을 반영하고 있으며 순간적인 감정상태를 반영하는데 문제가 있음을 알 수 있다.

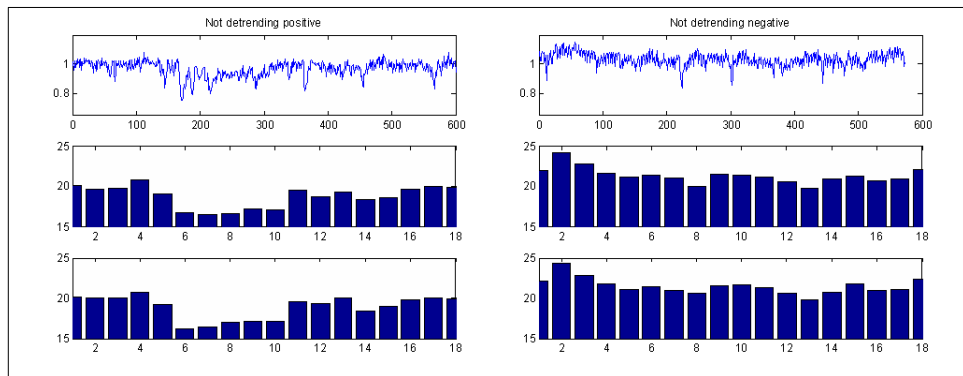


그림 3-5 저주파 제거를 하지 않은 주성분 분석 결과 (특징값 1, 특징값 2)

그림 3-6 은 1차 선형 저주파 제거를 한 후 주성분 분석을 한 결과다. 긍정적인 감성 선형적인 저주파 제거를 한 신호 역시 저주파 제거를 하지 않았을 때 보다 좋지 않은 결과를 나타내고 있다. 이 방법은 일반적인 주성분 분석을 행할시 구간의 평균값을 빼주고 고유값을 구하게 되는데, 선형저주파 제거 방법과 흡사한 방법이다. 그러므로 저주파 제거는 비선형저주파 제거 방법을 이용해서 순간적인 신호의 변화에 대한 주성분 분석을 함으로써 고유값을 찾는 것이 감정상태를 대변할 수 있는 특징값을 찾는 일이라 하겠다.

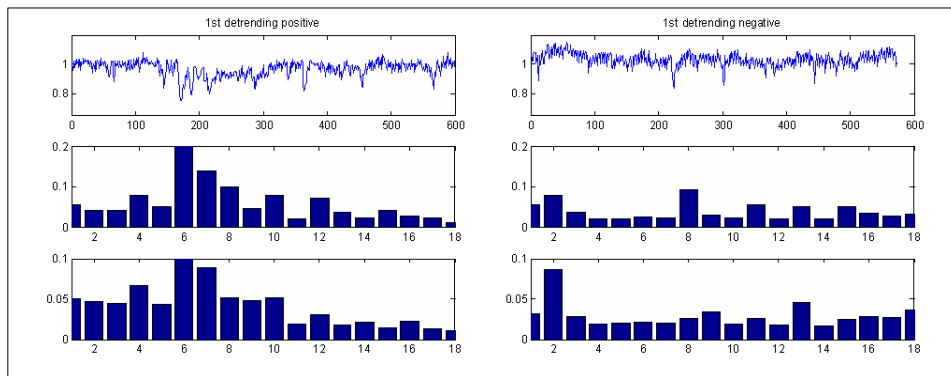


그림 3-6 선형 저주파 제거를 이용한 주성분 분석 결과  
(특징값 1, 특징값 2)

### 3.2 피부전도도의 신호처리 과정

피부전도도 (GSR: Galvanic Skin Response)는 저 전류를 인가한 2개의 전극 사이의 전압을 측정했다. 얻어진 샘플을 250Hz에서 20Hz로 다운 샘플링 해주었으며 평균필터를 통과시킨 신호와 원래 신호를 빼줌으로써 DC 가 제거된 고주파(high frequency)성분만을 얻어냈다. 미분을 통해 신호의 변화 점을 검출했다. 이와 같은 방법은 피부전도도 신호의 영점교차율을 계산해서 교감신경의 활성 정도를 정량적으로 평가할 수 있는 것으로 보편적으로 쓰이고 있다. 피부전도도의 계산 과정은 자세히 기술하겠다.

#### 영교차율(Zero-crossing Rate)

스펙트럼에서 에너지가 집중되는 주파수를 찾는 데 유용한 특징 파라미터로 널리 사용되는 영교차율은 분석구간 프레임 내에서 신호 파형이 영점(zero)측과 교차하는 횟수를 말한다. 피부전도도 신호를 미분한 신호는 감정상태가 보통이거나 흥분이 전혀 이루어지지 않은 경우 진폭이 크지 않고, 꽤 자극으로 흥분되어 있거나 불쾌자극으로 흥분 되어있을 때 불규칙적인 진동이 계속 있으므로 일정한 만큼만 중심축을 통과하는 보다 영교차율이 크다. 즉, 감정 신호에서 감정의 변화로 인해 교감신경의 활동이 활발하게 되어 신호의 진동이 발생하게 된다. 영교차율에 대한 일반식을 기술하면 다음과 같다.

$$Z_n = \sum_{m=-\infty}^{\infty} |sgn[x(m)] - sgn[x(m-1)]|w(n-m) \quad (16)$$

$$w(n) = \begin{cases} \frac{1}{2N} & 0 \leq n \leq N-1 \\ 0 & otherwise \end{cases} \quad (17)$$

$$sgn[x(m)] = \begin{cases} 1 & x(m) \geq 0 \\ -1 & x(m) < 0 \end{cases} \quad (18)$$

영교차율은 실험자의 개인적 성향 차이에 적게 의존하며 진동이 많이 발생하는

고주파는 높은 영교차율을 의미하며 감정의 변화가 적게 일어나서 생기는 저주파는 낮은 영교차율을 의미하므로 영교차율과 주파수의 에너지 분포에는 밀접한 관련이 있다.

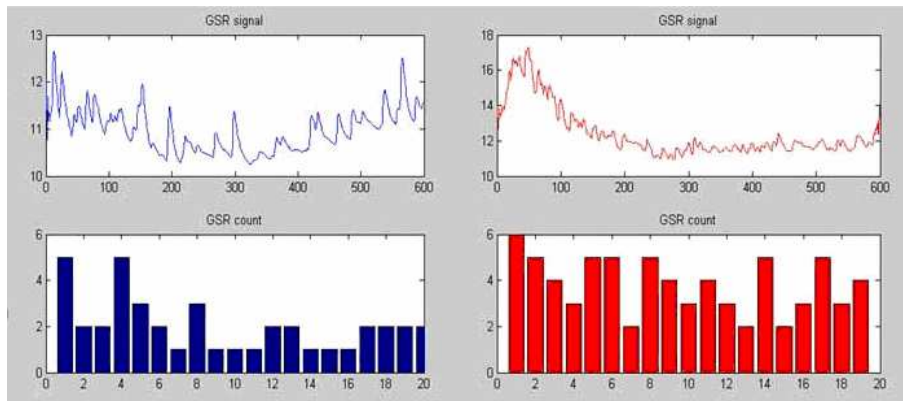


그림 3-7 영교차율을 이용한 피부전도도 특징값 검출 (실험자 1)

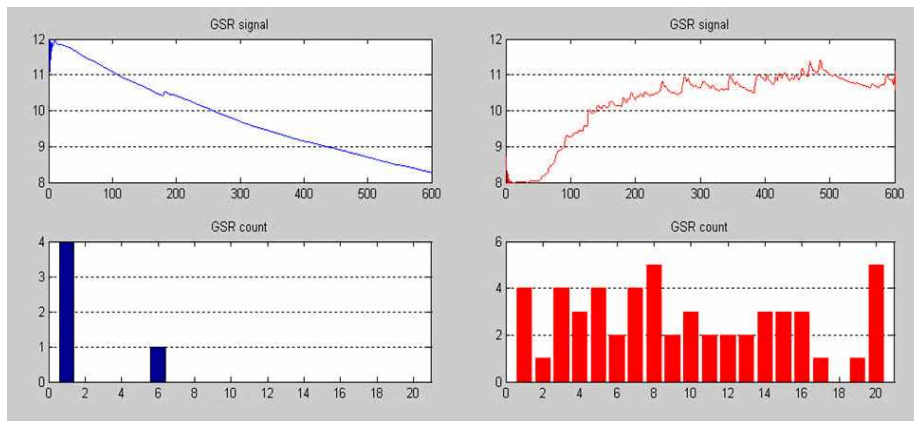


그림 3-8 영교차율을 이용한 피부전도도 특징값 검출 (실험자 2)

그림 3-7 와 그림 3-8 에서는 감정유발에 따른 피부전도도 신호의 변화를 보여

주고 있다. 대부분의 실험자에게서 피부전도도는 감정변화에 민감하게 반응했고 특히 불쾌 감정유발 자극이 이루어졌을 때 그림 3-7 에서 보는 것과 같이 신호가 진동하는 특성이 나타났고, 자극에 대한 반응 속도가 빠르게 나타났기 때문에 피부전도도는 감정 판별에 중요한 파라미터로 가정할 수 있다.

실험자 25명 중 쾌 감정일 때 그림 3-7 와 같이 흥분한 사람이 있는 반면, 그림 3-8 에서처럼 교감신경의 흥분 정도가 나타나지 않은 실험자가 있었다. 피부전도도 신호는 여러 논문에서 소개한 방법으로 흥분 정도를 정량적으로 계산한 결과 그림 3-7, 그림 3-8 와 같이 쾌 감정유발 상태와 불쾌 감정유발 상태의 차이를 나타낼 수 있었다.

### 3.3 피부온도의 신호처리 과정

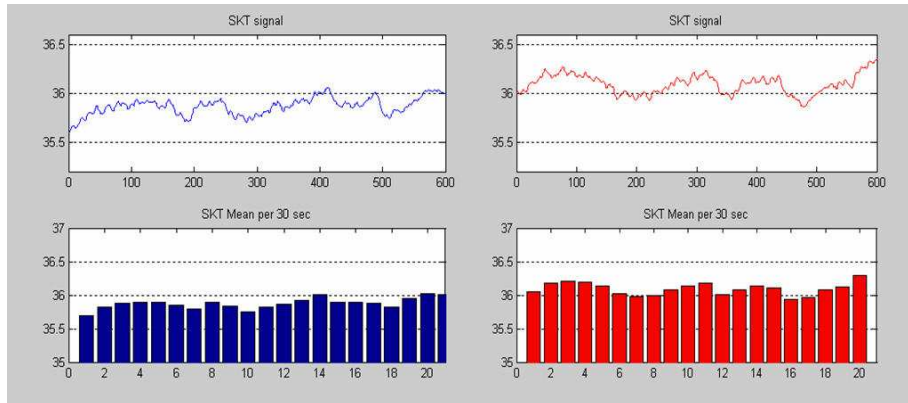


그림 3-9 감정유발에 따른 실험자의 평균 피부온도 변화

그림 3-9 에서 보여주는 것과 같이 대부분의 실험자는 불쾌 감정상태일 때 피부 온도가 올라감을 나타냈다. 하지만 불쾌 감정상태일 때 체온이 낮아지는 실험자가 있었고 실험실에 온도에 영향을 받았을 수도 있으므로 상대적으로 낮은 순위를 갖는 파라미터로 평균 피부 온도(mean skin temperature)를 선정했다.

평균 피부 온도는 식 (18)을 통해 30초간 피부온도의 평균값을 계산해주었다.

$$SKT\_mean_k = \frac{1}{M} \sum_{k=1}^M skt_k \quad (18)$$



### 3.4 데이터 정규화 (Data Normalization)

생체신호를 이용한 감정을 추정학습에는 여러 가지 고려해야 할 문제점들이 존재한다. 첫 번째로 피부전도도에서 보여주는 것과 같이 각 실험자에게 얻어진 데이터는 실험자마다 편차가 존재하며, 자극에 가장 잘 반응하는 생체신호가 서로 다르기 때문에 실험자간의 차이를 제거하고 감정의 종류에 따른 추론을 위해서는 정규화가 필요하다. 정규화를 위해서 아래와 같은 방법으로 개인별 평균값과 편차값을 제거시켜주었다.

$$\tilde{X}_n = \frac{X_n - \mu_x}{\sigma_x}, \quad \mu_x = \frac{1}{N} \sum_{n=1}^N X_n, \quad \sigma_x = \left( \frac{1}{N} \sum_{n=1}^N (X_n - \mu_x)^2 \right)^{\frac{1}{2}}$$

$$i = 1, 2, 3 \dots n$$

두 번째로 정규화를 통해 얻어진 데이터라 할지라도 생체신호는 비선형적이고 Nonstationary하기 때문에 감정 패턴을 선형적으로 구별할 수 없다.

그러므로 선형적으로는 감정에 대한 구분이 모호하기 때문에 비선형적인 감정 추론 과정이 필요하다. 본 연구에서는 몇 개안되는 생체신호만으로 가능한 감정추론의 정확도를 높이기 위해 Reduced Model, 신경회로망과 SVM을 이용해서 비선형적인 패턴을 학습하고 분류하려 한다.

### 3.5 생체신호처리의 전체 시스템 구성도

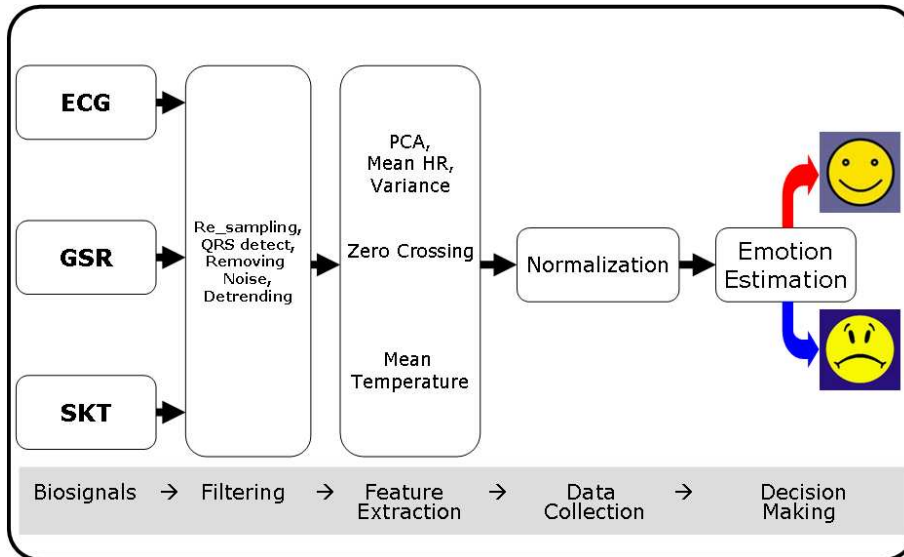


그림 3-10 감정 검출 알고리즘의 전체 시스템 구성도

그림 3-10 은 본 연구의 처음과 끝을 보여주고 있다. 생체신호를 이용한 데이터 취득부터 시작해서 신호처리부분, 특징 추출부분, 데이터 정규화, 마지막으로 감정 추론까지 상당히 많은 부분을 다루고 있다. 지금까지는 감정추론을 제외한 모든 부분을 설명했고 이제 감정 추론에 적합한 추론알고리즘을 소개하고 본 연구에서 다룬 알고리즘을 설명할 것이다.

## 제 4 장 패턴인식 알고리즘을 이용한 감정 인식

### 4.1 선형판별함수 (Linear Discrimination Function)

유비쿼터스 환경에서 이동형 디바이스를 통해 생체신호를 계측하고 측정된 신호를 통해 감정상태를 추정하는 역할을 하는 함수를 구하는데 가장 기초적이고 구현이 간단한 선형판별함수를 소개한다. 기본적으로 학습과정과 test과정이 분리되어 있고 적은수의 학습 데이터일지라도 학습계수 벡터를 결정하는 신뢰성 있는 데이터라면 test 할 때 전혀 영향을 미치지 않는다. 하지만 학습데이터 자체가 학습계수를 결정짓는데 불충분하다면 test 때 정확성이 떨어지는 함수를 구성하게 된다.

선형판별알고리즘은 학습데이터  $Y$ 는  $(n \times (d+1))$  행렬로 이루어져 있고 목표 값을 벡터  $b$  ( $n \times 1$ )로 설정해주고 알지 못하는 가중치 벡터  $a$  를 구하는 방법이다.

$$\begin{pmatrix} y_{10} & y_{11} & \cdots & y_{1d} \\ y_{20} & y_{21} & \cdots & y_{2d} \\ \cdots & \cdots & \cdots & \cdots \\ y_{n0} & y_{n1} & \cdots & y_{nd} \end{pmatrix} \begin{pmatrix} a_0 \\ \cdots \\ a_d \end{pmatrix} = \begin{pmatrix} b_1 \\ b_2 \\ \cdots \\ b_n \end{pmatrix}, \quad Ya = b$$

최적의 선형 분별 가중치 벡터  $a$ 를 구하기 위해  $Ya$ 와  $b$ 의 값의 차이를 최소화 하기 위해  $Ya$ 와  $b$ 의 차를 구하는 식은 다음과 같다.

$$e = Ya - b$$

$e$ 값을 최소화 하기 위해 제곱의 합이 최소가 되는 값을 찾는다.

$$J_s(a) = \|Ya - b\|^2 = \sum_{i=1}^n (a^t y_i - b_i)^2$$

최소 값을 찾기 위해 아래와 같이  $a$  에 대해서 미분하고 이항과정을 거치면 원하

는 가중치 벡터  $a'$ 를 구할 수 있다.

$$\nabla J_s = \sum_{i=1}^n 2(a' y_i - b_i) y_i = 2Y'(Ya - b)$$

$$Y'Ya = Y'b$$

$$a' \approx (Y'Y + \epsilon I)^{-1} Y'$$

그러므로 식  $a' \approx (Y'Y + \epsilon I)^{-1} Y'$ 에서 원하는 가중치 벡터를 얻음으로써 새로운 데이터  $X$ 가 입력으로 들어 왔을 때 계산된 가중치 벡터  $a'$ 를 이용해서 결과  $O_{predict} = a' X'$ 를 예측할 수 있다.

#### 4.2 Reduced Multivariate Polynomials Model

다 변수 다항식 모델(Multivariate Polynomial Model)은 복잡하고 비선형적인 입출력을 표현하는 것에 대해 효과적인 방법을 제공한다. 왜냐하면 다 변수 다항식 모델은 최적화(Optimization), 민감도 분석(Sensitivity analysis)을 하는데 적용하기 용이하기 때문이다. 그러나 다변수 다항식 모델은 고차원(High-dimension, High-order)와 다 변수 다항식 회귀(regression)은 상당히 많은 곱셈연산이 있기 때문에 엄청난 계산량으로 인해 비실용적이다. 다변수 다항식 모델의 형태를 이용하면서 이와 같은 문제점을 해결하기 위한 방법으로 Reduced Multivariate polynomial Model (RM)이 있다. RM을 이용해서 파라미터의 수가 급격하게(exponential) 증가하지 않고 분류 능력(classification capability)을 유지할 수 있도록 한다.

#### Multivariate Polynomial Regression (MP)

다 변수 다항식의 특별한 경우를 Multinomial이라 한다. Multinomial을 수식으로 표현하면 다음과 같다.

$$(x_1 + x_2 + \dots + x_l)^r = \sum \frac{r!}{n_1! n_2! \dots n_l!} x_1^{n_1} x_2^{n_2} \dots x_l^{n_l}$$

$n_1, n_2, \dots, n_l$  는 음수가 아닌 정수이고  $n_1 + n_2 + \dots + n_l = r$  의  $r$  은 추정 차수(order) 다. Multinomial model의 총 개수가  $K+1$ 이라 가정하면 추정을 위한 가중치 파라미터벡터  $\boldsymbol{\alpha} = [\alpha_0, \alpha_1, \dots, \alpha_K]^T$  와 곱해짐으로써 (Multinomial - 1)식을 만들 수 있다.

$$\hat{f}_{MN}(\boldsymbol{\alpha}) = \alpha_0 + \sum_j \alpha_j (x_1^{n_1} x_2^{n_2} \dots x_l^{n_l}),$$

(Multinomial - 1)  $j = 1, 2, \dots, K$

또 다른 형태의 경우로 식을 한 덩어리로 표현하는 방법으로 (Multinomial - 2)의 식이 있다.

$$\hat{f}_{MN}(\boldsymbol{\alpha}) = \alpha_0 + \sum_{j=1}^r \alpha_j (x_1 + x_2 + \dots + x_l)^j$$

(Multinomial - 2)

Weierstrass의 추정이론에 의하면 다항식의 추정 능력은 이미 검증이 되어 있는 사실이다. 연속적인 함수의 형태로 나타남으로써 함수가 표현할 수 있는 구간에 있는 모든 데이터 값을 무리 없이 추정할 수 있는 장점이 있다. 그러나 위에서 언급했다시피 입력과 차수의 증가에 따라 식의 규모가 엄청나게 증가한다는 단점이 있기 때문에 다 변량 다항식을 직접 사용하는 것에 대해 무리가 있다.

그래서 다 변수 다항식을 간략화 시킨 (Multinomial - 1)과 (Multinomial - 2)는 식의 규모를 상당히 줄였다. 하지만 (Multinomial - 1)은 고차원의 식만을 사용하기 때문에 추정함수를 표현하는데 부족함이 있고 (Multinomial - 2)는 표현하는 차수에 영향을 많이 받기 때문에 이것 역시 추정함수를 표현하는데 무리가 있다. 이와같은 단점을 보완한 Reduced 모델에 대해서 설명하겠다.

### A Redeced Multivariate Polynimials Model

RM 모델은 상당히 큰 규모의 다항식을 줄이는 것이 목적이기 때문에 우선적으로 다음의 Multinomial 비선형 추정 모델을 고려하겠다.

$$\hat{f}_{\text{MN}} = \alpha_0 + \sum_{j=1}^r (\alpha_{j1}x_1 + \alpha_{j2}x_2 + \cdots + \alpha_{jl}x_l)^j.$$

이것의 가중치 벡터는  $\alpha_{jk}, j = 1, \dots, r, k = 1, \dots, l$ 는 직접적인 방법으로 구하기 힘들다. 비록 선형분류함수와 같은 방법으로 구할 수 있지만 얻어지는 가중치 벡터의 값이 전역적으로 최적의 값이 아닐 수 있다. 다시 말해서 지역 최소점(Local Minimum)에 빠질 수 있다. 이런 문제점을 비하기 위해 선형화된 모델을 고려할 것이다.

미분할 수 있는 두 개의 포인트  $\alpha$  와  $\alpha_1$ 이 있다고 가정하면, 평균값 이론(mean value theorem)에 의해서 multinomial 함수  $f(\alpha)$  를 다음과 같이 표현할 수 있다.

$$f(\alpha) = (\alpha_{j1}x_1 + \alpha_{j2}x_2 + \cdots + \alpha_{jl}x_l)^j, \\ j = 2, \dots, r$$

$\alpha_1$  에서 대해서  $f(\alpha) = f(\alpha_1) + (\alpha - \alpha_1)^T \nabla f(\bar{\alpha})$  과 같이 표현할 수 있다. 단,  $\bar{\alpha} = (1 - \beta)\alpha_1 + \beta\alpha$  ,  $0 \leq \beta \leq 1$ 의 조건이 있다.

식  $f(\alpha) = f(\alpha_1) + (\alpha - \alpha_1)^T \nabla f(\bar{\alpha})$  을 기반으로 식을 표현하면 다음과 같은 식으로 나타낼 수 있다.

$$\begin{aligned}
\hat{f}_{\text{RM}'} &= \alpha_0 + \sum_{j=1}^l \alpha_j x_j \\
&+ \sum_{j=1}^r \alpha_{l+j} (x_1 + x_2 + \cdots + x_l)^j \\
&+ \sum_{j=2}^r (\boldsymbol{\alpha}_j^T \cdot \mathbf{x}) (x_1 + x_2 + \cdots + x_l)^{j-1}, \\
& \quad l, r \geq 2
\end{aligned}$$

단, 식의 규모를 표현할 수 있는  $K$ 가  $K = 1 + r(l + 1)$ 다. 위의 식  $\hat{f}_{\text{RM}'}$ 을 기반으로 고차원 부분을 강조한 식으로 다시 쓰면 다음과 같다.

$$\begin{aligned}
\hat{f}_{\text{RM}} &= \alpha_0 + \sum_{k=1}^r \sum_{j=1}^l \alpha_{kj} x_j^k \\
&+ \sum_{j=1}^r \alpha_{rl+j} (x_1 + x_2 + \cdots + x_l)^j \\
&+ \sum_{j=2}^r (\boldsymbol{\alpha}_j^T \cdot \mathbf{x}) (x_1 + x_2 + \cdots + x_l)^{j-1} \\
& \quad l, r \geq 2.
\end{aligned}$$

수식의 규모를 나타내는  $K$ 는  $1 + r + l(2r - 1)$ 로 나타낼 수 있다. 그러므로

식  $\hat{f}_{\text{RM}'}$ 은 식  $\hat{f}_{\text{RM}}$ 보다  $(rl - l)$ 개 많은 수의 수식 규모를 나타낸다. 그러므로 제안된 RM 모델은 수식의 규모와 모델의 차수(order, dimension)을 비교해 볼 때 선형적인 관계를 나타낸다. 이것에 대한 비교를 그림 4-1.로 나타내었다.


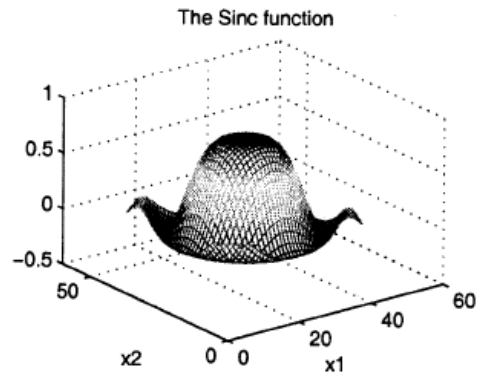



그림 4-1. 입력의 order와 dimension에 따른 수식의 규모

또 그림 4-2.에서는 9차 RM 모델로 sinc함수를 표현한 그림이다. (Multinomial - 1)과 (Multinomial - 2) 역시 sinc함수를 나타내게 함으로써 RM 모델의 우수성을 나타냈다.







(a) Multinomial (MN9-I)



(b) Multinomial (MN9-II)



(c) Reduced Model (RM9)



(d) Multivariate Polynomial (MP9)




그림 4-2. sinc 함수 추정 (a) 9차 Multinomial - 1 (b) 9차 Multinomial - 2  
(c) 9차 RM (d) 9차 MP

### 4.3 신경회로망(Neural Network)

컴퓨터의 발달과 더불어 다양한 분야에서 인간과 같은 형태로 인식하고, 계산하며, 판단할 수 있도록 하려는 많은 시도가 있었다. 인간의 두뇌는 기존의 컴퓨터가 가지지 못하는 여러 가지 특성을 가지고 있다. 이러한 특징으로는 오차에 대한 견고성(robustness) 및 내고장성(fault-tolerance), 학습(learning)을 통한 새로운 환경에 대한 적응성, 유연성, 확률적이고 잡음이 있으며 일관되지 않는 정보를 다룰 수 있는 특성, 그리고 고차원적인 병렬분산처리 체계 등이 있다. 패턴인식, 의사결정 등에 있어 고성능 컴퓨터보다 인간의 두뇌가 뛰어난 점에 착안하여 신경회로망 이론이 탄생하게 되었다. 신경회로망은 인간의 두뇌와 신경세포조직의 생물학적 작용에 대한 여러 가지 연구 사실을 근거로 제안된 병렬분산처리 체계(parallel distributed system)이다. 주변 뉴런으로부터 스칼라(scalar)값을 전달받은 뉴런은 각각의 스칼라 값에 가중치(weight)를 곱하여 합산한 결과를 활성화함수(activation function)에 입력하고, 활성화함수로부터의 출력은 다시 다음 층의 뉴런의 입력 값이 된다. 신경회로망을 한마디로 요약하면 학습에 대한 적응성과 병렬분산처리 체계의 혼합이라고 할 수 있다.

신경회로망의 구조는 기본적으로 단위세포는 외부 신호를 받아들이는 입력소자와 각 입력소자와 활성화함수, 그리고 단위세포의 최종응답을 출력하는 출력 소자로 구성된다. 그림 4-3은 신경회로망의 기초인 McCulloch & Pitts의 뉴런을 도식화한 것으로 그 구조와 전달과정을 나타내고 있다. 그림 4-3에서 보이는 입력 뉴런은 각각의 가중치  $w$ 를 곱하게 되고 적절한 바이어스(bias)를 주고 활성화 함수를 통해 출력하게 된다. 결국 McCulloch & Pitts의 뉴런은 다른 뉴런으로부터의 입력 값의 가중 합을 계산하고, 활성화 함수가 계단함수의 특성을 가지고 있다면, 그 값이 임계 값을 초과할 경우에 활성화된 상태로 값을 출력하게 되며, 그렇지 않을 경우 0의 값을 가지게 된다.

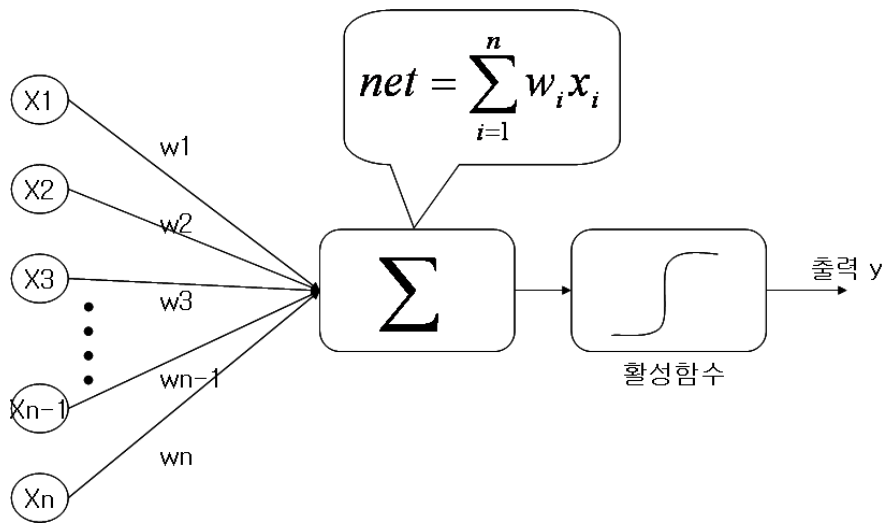


그림 4-3. 신경회로망의 기초적인 구조와 전달과정

가장 널리 사용되는 다층 신경회로망(multilayer perceptron)의 전형적인 구조를 살펴보면 입력 층에는 입력벡터를 뜻하는 입력 뉴런이 있고, 출력 층에는 출력 벡터를 뜻하는 출력 뉴런이 있다. 그리고 이들을 상호 연결하는 은닉 층(hidden layer)의 각 뉴런이 연결가중치로 연결되어 있어서, 많은 입출력에 의해 상관관계를 결정짓는 역할을 하고 있다.

#### 활성화 함수

각 뉴런에는 전 단계에 위치한 뉴런으로부터의 출력 값에 연결가중치를 곱한 값들이 합해진 상태의 입력 값으로 들어온다. 뉴런은 입력 값을 활성화 함수를 거쳐 출력 값으로 내보내게 된다. 뉴런의 활성화 함수는 일반적으로 시그모이드(sigmoid)함수, 선형(linear)함수, 역탄젠트 함수, 계단함수(step)등이 많이 사용되고 있다. 신경회로망의 입출력관계에서의 활성화 함수는 일반적으로 비선형적인 특성을 가진다.

신경회로망의 장점에는 지식의 저장(storing knowledge), 적응성 및 일반화 특성(adaptive ability & generalization), 함수 근사화(system identification), 병렬처리 기능(parallel processing), 여과기능(filtering function) 등이 있다. 이제부터 장점 5가지에 대해 자세히 소개 하겠다.

#### 1) 지식의 저장

신경망에 입력되어 학습의 과정을 거치면서 연결가중치가 변경되고, 변경된 결과는 계속 저장된다. 이는 연상기억(associative memory)처럼 비슷한 성질의 데이터를 기억할수 있는 능력을 갖춘 회로망이라는 것을 의미한다.

#### 2) 적응성 및 일반화 특성

신경회로망의 큰 특징 중 하나는 부족한 입력데이터에 대해서도 의사결정을 할수 있는 능력이 있다는 것이다. 신경회로망은 학습된 상태에 기초하여 그와 유사한 입력에 대해서 특별한 처리 없이 비교적 올바른 결과를 낸다. 학습된 자료와 다른 값이 입력되었을때에도 적절한 출력을 낼 수 있음을 의미한다. 따라서 불완전하거나 왜곡된 입력에 대해서도 효율적으로 대응할 수 있는 내 잡음성을 갖는다.

#### 3) 신경회로망에 의한 함수 근사화

함수 근사화와 이론은 신경회로망의 기본 특성 중에서 가장 중요한 것 중의 하나이다. 인간의 두뇌와 유사한 병렬처리 능력이 있는 신경회로망은 입출력의 관계가 비선형적이고 복잡한 경우에도 학습 과정을 통하여 상호관계를 사상하는 함수 근사화 문제를 해결할 수 있음이 잘 알려져 있다. 시스템의 수학적 모델링이 어렵거나 많은 가정이 필요한 다변수 함수의 근사화 문제에 대해서도 기존의 함수 근사화 방법에 비하여 복잡한 수학적 모델링이 요구되지 않는다는 장점이 있다.

#### 4) 고유의 병렬처리 기능

신경회로망의 또 다른 특징은 뉴런이라는 기본 단위로 이루어진 병렬 구조라는데 있다. 따라서 현재 개발되고 있는 병렬 처리 하드웨어를 통해 신경회로망을 구

현한다면, 고속으로 대량의 데이터를 실시간으로 처리하고자 할 때 기존의 순차적인 처리구조의 컴퓨터에는 실현이 어려웠던 분야에 대해서도 적용이 가능하게 된다.

#### 5) 여과기능

신경회로망의 여러 층은 여과기능을 한다. 이는 신호가 한 층을 지날 때마다 결합강도가 작거나 기준치를 넘지 못하는 출력은 winner-take-all 방법에 의해 억제되기 때문이다.

그렇다고 신경회로망이 최고의 해결책은 아니고 실제로 모델링을 하거나 사용하고자 할 때 몇 가지 고려해야 할 문제점들이 있다. 이러한 문제점들은 신경회로망의 단점이기도 한다. 첫 번째로 신경회로망은 입출력 관계에 의한 계산식이 수식적으로 분명한 경우에는 학습오차와 오차 때문에 신경회로망이 오히려 불리하게 된다. 계산절차가 분명하고 수식이 있는 경우에는 본노이만 형식의 일괄처리 방식의 컴퓨팅 방식이 유용하다.

두 번째로 신경회로망을 구성하는 방법에는 보편타당한 규칙이 없어 경험에 의존해야 한다. 대부분의 신경회로망은 모멘텀(momentum), 학습률(learning rate), 은닉층 개수와 뉴런의 개수와 같은 설계 파라미터를 주어진 문제 해결에 적합하도록 선정하는 문제에 대하여 일반적인 방법이 없으므로 설계자의 직관에 의해서 시행착오적으로 결정할 수밖에 없다.

세 번째로 신경회로망은 대체로 간단한 문제에는 쉽게 학습이 수행되나, 자연계 현상을 해석하는 문제와 같이 복잡한 문제에 대해서는 학습이 어렵다는 단점이 있다. 이 경우 대부분 학습대상을 축소하거나, 모델링 단계에서 주의 깊은 고찰이 요구된다.

네 번째로 데이터가 불충분하거나 이들 사이에 학습 가능한 함수 관계가 존재하지 않으면 만족한 해답을 찾지 못할 수도 있다.

다섯 번째로 신경회로망에 의해서 얻어진 결과에 대해 적절한 설명이 어렵다. 이것은 신경회로망에 의해 얻어진 결과가 수많은 가중치와 입력 패턴의 연산을 통

해 이루어졌고, 가중치는 복잡한 학습(machine learning)에 의해 결정된 것이기 때문에 기존의 방법에 의해 얻어진 결과에 대한 해석은 거의 불가능하다. 따라서 예상되는 모든 입력 값을 통해 이를 시험해 볼 수 없다면 안전성이 심각한 문제가 되거나 위험 부담을 피해야 하는 분야에 대해서는 적절하지 않을 수 있다.

여섯 번째로 신경회로망은 학습시에 매우 많은 시간과 비용을 소비할 수도 있다. 학습데이터를 선정, 분석, 처리하는 일이나 최적의 파라미터를 구하는 일에서 이러한 부담은 항상 내포되어 있다. 그러나 학습대상에 대해 확실하게 이해하는 상태에서 병렬처리 하드웨어를 이용해 작업을 진행한다면 이러한 부담을 줄일 수 있다.

일곱 번째로 신경회로망의 계산속도에 문제가 있다. 각 유닛간의 연결은 곱셈을 의미하므로 전체 연산에 대한 수행 속도는 연결의 수에 관계된다. 따라서 약간의 유닛 수의 증가로 전체 수행시간은 크게 늘어난다. 따라서 실시간 처리를 위해서는 병렬처리 하드웨어가 필요하게 된다.

따라서 위와 같은 결점들을 극복하고 신경회로망의 장점을 살리기 위해서는 대상 문제의 특성을 올바르게 파악하고 이에 따라 신경회로망에 대한 적절한 응용모델을 선정해야 한다.

### **신경회로망의 종류 및 다층 신경회로망(Multilayer perceptron)**

신경회로망에는 다양한 종류가 있으면 그 성능과 응용범위도 다양하다. 신경회로망의 종류는 각 뉴런을 연결하는 시냅스가 연결되는 형태에 따라서 크게 recurrent와 nonrecurrent 신경회로망 모델로 나누어 질수 있다. Nonrecurrent 신경회로망은 다시 상호 결합형(auto associative neural network)과 계층형(feedforward neural network)으로 나누어진다. recurrent신경회로망 모델은 출력값의 케환이 있으므로 공간 패턴뿐만 아니라 시간패턴 까지 인식할 수 있어 nonrecurrent 신경회로망 보다 강력한 성능을 발휘하거나, 작동 특성이 매우 복잡한 단점이 있다.

계층형 모델은 대표적인 nonrecurrent 신경회로망으로서, 가장 널리 쓰이고 있으며 응용범위가 넓다. 계층형 신경회로망은 다시 신경회로망과 다층형 신경회로망(multi-layer feedforward neural network)으로 나뉜다. 다층형 신경회로망은 한 개의 입력층, 한 개의 출력층, 그리고 복수의 은닉층으로 구성되고, 같은 층의 뉴런 간 연결은 없다. 이때 입력층은 일반적으로 활성화 함수를 갖지 않고 입력 값을 바로 은닉층으로 전파하는 구조이며, 학습은 주로 오류 역전파 알고리즘(error back-propagation algorithm)을 사용한다.

다층 신경회로망을 설계함에 있어 중요한 인자는 입출력 벡터의 선택과 은닉층의 크기, 즉 은닉층 단위 소자인 뉴런의 개수인데, 이러한 인자들은 문제마다 다르고 임의성을 가진다. 은닉층은 신경회로망의 비선형적인 특성을 나타내는 향으로 은닉층의 크기를 잘못 설정한 경우에는 학습이 잘 진행되지 않고 추론된 결과도 정확성이 보장되지 않는다.




그림 4-4 순방향 신경회로망의 모델

그림 4-4 는 순방향 신경회로망 모델을 나타내고 있다. 그림에서 보듯이 퍼셉트론 모델은 입력 층, 은닉 층, 출력 층으로 구성되는데, 이 모델의 비선형성에 대한 한계를 보완하기 위해서 입력 층과 출력 층 사이에 하나 또는 그 이상의 은닉 층을 가진 다층 신경회로망 모델이 제시 되었다. 입력 층과 출력 층은 각각 외부로부터의 입력을 받아들이는 역할과 결과를 출력하는 역할을 수행하며, 은닉 층은 입력 층으로부터 출력 층으로의 계산과정에 이용된다. 각 층 사이에는 연결가중치가 존재하며 이들은 두 성분들 사이의 연결정도를 나타내는데, 주어지는 입력과 출력에 따라 연결가중치를 조절해 나간다.

신경회로망 연결 가중치의 적절한 값을 구하기 위해서 일정한 범위 내의 임의의 초기값에서 시작하여 지속적인 개선을 수행하며 이 과정을 학습(learning)이라 한다. 신경회로망 학습방법에 따라 지도학습(supervised learning)모델과 자율 학습 모델(unsupervised learning)로 크게 나눌 수 있다. 지도학습에서는 신경회로망의 출력 값과 비교할 수 있는 목표값이 존재하며, 그 오차를 이용해서 학습을 수행하게 된다. 이와 반대로 자율학습에서는 정답이 존재하지 않으며, 이용 가능한 정보로써 입력 자료들 또는 신호만이 제공된다. 자율 학습에서는 신경회로망이 스스로 입력 자료에서 흥미 있는 범주나 특징을 발견해야 하므로, 정확한 정보없이 자기 조직화에 의한 훈련을 하고 결과를 출력한다.

신경회로망의 학습은 두뇌와 마찬가지로 단위 세포간의 연결 가중치를 일정한 규칙에 따라 조절한다. 신경회로망의 학습을 위하여 연결가중치를 조절하는 인정한 규칙을 학습규칙이라 한다.

#### **오류 역전파 알고리즘**

다층 퍼셉트론을 학습 시키는 대표적인 방법이 역전파 알고리즘이다. 학습에는 입력 패턴과 이에 대응하는 목표값을 쌍으로 해서 학습패턴에 이용되는데, 입력 패턴을 입력층에 인가하고 임의의 초기값으로 주어진 연결 가중치에 의해 출력되는 출력 패턴과 목표 패턴을 비교하여 그 오차 만큼을 역으로 전파하여 연결가중치



를 수정한다. 이러한 작업은 모든 학습 패턴에 대해 이루어지며, 학습 패턴에 대한 오차가 기준값 이하로 떨어지면 학습을 멈춘다. 이와 같이 학습이 끝난 신경회로망은 학습 패턴은 물론 불완전한 패턴이나 학습되지 않은 패턴이 입력된다 하여도 적절한 출력을 내게 된다.

역전파 알고리즘에 의해서 신경회로망을 학습할 경우 일반적으로 지역 최소값(local minimum)에 대한 문제가 발생한다. 즉, 오차 함수의 모양이 복잡하여 여러 개의 국소적인 최소값이 존재할 경우, cross validation 기법을 통해 신경회로망을 지역 최소값 또는 overfitting 문제에서 해결할 수 있다.

그럼 지금부터 오류 역전파 알고리즘에 대해 설명하겠다. 오류 역전파 알고리즘은 기울기 하강법(gradient descent)과 최소자승법을 기념개념으로 하고 있다. 식 (19)은 다음의  $w(m+1)$ 은 현재의  $w(m)$ 에  $\Delta w(m)$ 를 더한 값이다.

$$w(m+1) = w(m) + \Delta w(m) \quad (19)$$

기울기 하강법은 목표 값과 출력 값의 차이 값을 최소로 하는 법으로 식 (20)이 나타내 주고 있으며,

$$J(w) = \frac{1}{2} \sum_{k=1}^c (t_k - z_k)^2 = \frac{1}{2} \|t - z\|^2 \quad (20)$$

우리는 여기서  $\Delta w(m)$ 를 구하는 법을 소개한다. 식 (20)의  $J(w)$ 를  $w$ 로 미분하면  $\Delta w(m)$ 를 구할 수 있다.

$$\Delta w = -\eta \frac{\partial J}{\partial w} \quad (21)$$

우선 목표값과 출력값의 기울기 하강식 (20)를 목표값과 은닉층의 연결노드( $w_{kj}$ )로 미분한다. 미분된 식은 chain-rule에 의해서 식 (22) 와 같이 나타내어질 수 있다.

$$\frac{\partial J}{\partial w_{kj}} = \frac{\partial J}{\partial net_k} \cdot \frac{\partial net_k}{\partial w_{kj}} = -\delta_k \frac{\partial net_k}{\partial w_{kj}} \quad (22)$$

Chain-rule에 의해 만들어진 식 (22)에서 J 를  $net_k$ 에 의해 미분한 식을  $\delta_k$ 로 나타낸다.

$$\delta_k = -\frac{\partial J}{\partial net_k}$$

$\delta_k$  는 다시 chain-rule에 의해서 식이 변형되며, 입력과 출력의 차에 대한 식이 되어  $t_k - z_k$ 가 된다.

$$\delta_k = -\frac{\partial J}{\partial net_k} = -\frac{\partial J}{\partial z_k} \cdot \frac{\partial z_k}{\partial net_k} = (t_k - z_k) f'(net_k)$$

그리고, 가중치로 이루어진 신경망(net)은 가중치(W)와 입력(y)의 곱으로 표현될 수 있으므로  $net_k = w_k^t \cdot y$  과 같이 쓸 수 있고 W에 대해 미분하면 y가 남게 된다.

$$\frac{\partial net_k}{\partial w_{kj}} = y_j$$

그러므로, 은닉층과 출력층 사이의 가중치 값은 식 (23)와 같이 표현할 수 있다.

$$\Delta w_{kj} = \eta \delta_k y_j = \eta (t_k - z_k) f'(net_k) y_j \quad (23)$$

그럼 입력 층과 은닉 층의 가중치 값은 어떻게 계산할 것인지 소개하겠다. 출력층과 은닉층의 계산과 같이 미분과 chain-rule을 통해서 식을 유추하게 된다.

$$\frac{\partial J}{\partial w_{ji}} = \frac{\partial J}{\partial y_j} \cdot \frac{\partial y_j}{\partial net_j} \cdot \frac{\partial net_j}{\partial w_{ji}}$$

$$\begin{aligned} \frac{\partial J}{\partial y_j} &= \frac{\partial}{\partial y_j} \left[ \frac{1}{2} \sum_{k=1}^c (t_k - z_k)^2 \right] = - \sum_{k=1}^c (t_k - z_k) \frac{\partial z_k}{\partial y_j} \\ &= - \sum_{k=1}^c (t_k - z_k) \frac{\partial z_k}{\partial net_k} \cdot \frac{\partial net_k}{\partial y_j} = - \sum_{k=1}^c (t_k - z_k) f'(net_k) w_{kj} \end{aligned}$$

$$\delta_j \equiv f'(net_j) \sum_{k=1}^c w_{kj} \delta_k$$

$$\Delta w_{ji} = \eta x_i \delta_j = \eta \underbrace{\left[ \sum w_{kj} \delta_k \right]}_{\delta_j} f'(net_j) x_i \quad (24)$$

결론적으로 식 (24)와 같이 입력층과 은닉층은 가중치의 기울기를 구할 수 있다.

이 과정을 반복을 통해서 가중치의 기울기가 사용자가 원하는 값 이하로 나타난다면 조건에 만족하여 학습 반복을 멈추게 된다. 신경회로망은 이처럼 사용자의 감독하에 학습하고 지역 최소에 빠지는 문제점이 있기 때문에, 신경회로망을 최적 구조로 설계하는 방법을 강구해야한다. 신경회로망의 설계는 신경회로망의 은닉층 개수, 은닉층 뉴런 수, 연결구조 등 구조자체에 대한 설계와 연결 가중치의 학습으로 나뉜다. 다층 퍼셉트론 신경회로망의 연결 가중치는 일반적으로 역전파 알고리즘으로 학습한다. 그러나 역전파 알고리즘은 신경회로망의 구조가 미리 정해져 있어야 한다는 단점이 요구되며, 신경회로망의 구조가 커짐에 따라 성능이 급격하게 떨어진다는 단점이 있다. 한편 유전자 알고리즘을 신경회로망을 학습방법으로 많이 사용하는데, 이 방법은 최적해 근처에서 수렴속도가 느린 단점은 있으나, 지역 최소값에 거의 빠지지 않으므로 전역 최적해를 찾는 성능이 우수하다.

신경회로망 구조 설계에 대해서는 다양하고 많은 연구가 이루어져 왔으며, 크게 다음의 세 가지 방법으로 크게 나눌 수 있다. 첫 번째 방법은 주어진 구조의 성능을 사전분석적인 방법으로 해석하고 설계하는 방법인데, 이 방법은 단순하지 않은 문제에서 적용하기 매우 어렵다. 두 번째는 신경회로망구조를 충분히 크게 하는 방법인데 이 방법은 학습시간이 너무 오래 걸려 비효율적이며 불필요한 구조 때문에 일반화 성능이 떨어진다는 문제가 있다. 세 번째 방법은 신경회로망을 처음에 어떻게 초기화를 해주어 학습을 펼쳐 나가는가에 대한 문제인데, 소량의 신경회로망을 구성한 후 학습을 통해 그 구조를 넓혀나가는 방법이 있다. 이 방법에 의해 생성된 신경회로망은 일반적으로 필요이상의 은닉층 뉴런을 갖게 되어 일반화 성능이 떨어진다. 반면에 신경회로망의 초기화를 큰 규모의 신경망으로 구성한 후 학습을 하면서 불필요한 망을 제거하는 방식이다. 이 방법을 통해 구해진 신경회로망은 비교적 일반화 성능이 뛰어나다. 그러나 아주 큰 규모의 신경회로망으로 구성해야하기 때문에 시간이 많이 걸리는데다가, 이렇게 학습된 신경회로망의 뉴런이나 연결을 제거하여 사용하지 않는다는 것이 아니라, 한정된 범위의 구조영역만 탐색할 뿐이다. 따라서 같은 시행착오에 의한 전통적인 접근 방법으로 구하여진 해가 전역 최적해라고 보기 힘들다.

#### 4.4 Support Vector Machine ( SVM )

SVM은 1995년에 Vladimir Vapnik에 의해 이원 패턴 인식 문제를 해결하기 위해 제안된 학습방법으로 부정예제로부터 긍정예제를 분류해 낼 수 있는 결정면을 찾아내는 분류모형이다(Vapnik 1999). 최근에는 SVM을 응용한 연구영역이 분자 인식, 얼굴 인식, 음성인식 등의 패턴 인식 분야뿐만 아니라 문서 범주화나 여러 가지 응용분야에 확장되고 있다.

SVM은 이원 패턴 분리를 위한 알고리즘으로 개발되었기 때문에 k개의 범주를 학습시키기 위해서는 여러 개의 SVM 분류기를 조합해서 분류 업무를 수행하여 다원 분류기를 확장하게 된다. 패턴 인식 분야에서는 SVM 이원 분류기를 다원 분류기로 확장하는 것과 관련된 다양한 연구가 수행되고 있으나, 감정상태에 따른 생체 신호에 대한 데이터 분야에서는 SVM 다원 분류기를 중심으로 고찰하는 연구가 거의 수행된 적이 없기 때문에 그 성능을 분석해 볼 필요가 있다.

SVM에서는 학습과정이 이루어지기 전에 사용자가 직접 파라미터 값을 결정해야 하며 파라미터 값에 따라 SVM의 성능은 달라지게 된다. 이렇게 미리 결정해야 하는 파라미터는 학습과정에서 마진폭과 분류 오류 사이의 타협점(trade-off)을 찾아주는 오류 패널티(penalty) 변수 C 값과 비선형 SVM에 적용되는 커널함수(kernel function)의 파라미터이다. 본 연구에서는 실험에 적합한 C 값과 값을 결정하고, 이를 바탕으로 다항식 커널함수 및 RBF 커널함수를 적용한 비선형 SVM 이 분류 성능을 비교 분석하였다.

SVM 분류기 구축을 위해서는 입력데이터  $x$ 와 지지벡터(support vector)  $X_i$ 는 비선형 함수를 이용해서  $\Theta(X)$ ,  $\Theta(X_i)$ 로 대체된 후, 특징 공간(feature space)으로 변형된다 ( $\Theta(\cdot) : R_n \rightarrow R_p$  ( $p \gg n$ )). 이 때, 커널함수  $K(X, X_i)$ 를 이용하면 입력공간(input space)과 특징공간에서의 역할이 한번에 처리되어 계산

상의 어려움을 덜 수 있다(Scholkopf et al. 1999).

SVM은 선형적으로 분리할 수 있는 학습 집단에 대해서는 최대 마진 분류기를 구축하는 선형 SVM을 이용하고, 선형적으로 분리할 수 없는 경우에는 커널함수를 이용한 비선형 SVM으로 분류한다.

SVM은 Vladimir Vapnik에 의해 처음 고안되었는데 그림처럼 선형 분리가 가능한 두 클래스를 구분지으며 마진(margin)을 최대로 하는 초평면  $w \cdot x + b = 0$ 을 찾는 문제다. 여기서  $w$ 는 가중치 벡터이고,  $x$ 는 입력벡터,  $b$ 는 기준값이다.

학습문서 집합을  $D = \{(x_i, y_i)\}$ 라고 할 때, 입력데이터  $x_i$ 가 범주(class)에 속하면  $y_i$ 는 +1의 값을, 그렇지 않으면 -1의 값을 갖는다. 결국 SVM은 다음을 만족하는 아래의 식에서 최적의  $w$ 와  $b$ 를 찾는 문제이다.

$$x_i \cdot w + b \geq +1 \quad (y_i = +1 \text{인 경우})$$

$$x_i \cdot w + b \leq -1 \quad (y_i = -1 \text{인 경우})$$

선형적으로 분리가 가능한 학습 집단에서는 최적의 초평면을 이용하여 최대 마진 분류기를 구축하며, 선형적으로 분리할 수 없는 경우에는 최적의 초평면 분류기 개념을 일반화시킨 소프트 마진 분류기를 구축하게 된다.




그림 4-5 선형 SVM의 최대 마진 분류 평면

그림 4-5 은 선형 SVM 최대마진분류기 (maximum margin classifier )를 보여주고 있다.

$$y_i (x_i \cdot w + b) \geq 1 \quad , i = 1, 2, 3 \dots , i$$

여기서  $\psi = \|w\|^2$ 이므로  $\|w\|$  가 최소가 되는 최적의 값을 결정해야 한다. 위의 식과 같은 제약조건하의 최적화(Constrained Optimization) 문제는 1차 영역(primal)에서의 해석과 2차 영역(dual)으로 나눌 수 있다.

1차 영역에서는 1차 변수  $w$ 와  $b$ 에 따라 최소화되어야 하며, 이를 라그랑즈 승수(Lagrange multipliers)  $\alpha_i$ 를 이용해서 표현하면 다음과 같다.

$$L(w, b, \alpha) = \frac{1}{2} (w \cdot w) - \sum_{i=1}^l \alpha_i \{ [(x_i \cdot w) - b]y_i - 1 \}$$

$$(\alpha_i \geq 0, \forall_i)$$

이 식의 안장점(saddle point)을 찾기 위해서 다음과 같은 조건식을 구할 수 있다.

$$\frac{\partial L(w_0, b_0, \alpha^0)}{\partial b} = \sum_{i=1}^l \alpha_i^0 y_i = 0$$

$$\frac{\partial L(w_0, b_0, \alpha^0)}{\partial w} = w_0 - \sum_{i=1}^l y_i \alpha_i^0 x_i = 0$$

위의 결과를 이용해서 다음과 같은 식을 만들 수 있다.

$$W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j (x_i \cdot x_j)$$

최적 초평면을 설계하기 위해서는 이식을 최대화하는  $\alpha$  를 구하는데 이는 2차 계획법(Quadratic Optimization)을 통해서 이루어진다. 이 과정을 통해서 최종적으로 얻어진 해는 다음과 같다.

$$w_0 = \sum_{\text{support vectors}} y_i \alpha_i^0 x_i$$

이 해를 이용해서 얻어지는 분류법칙은 다음과 같다.

$$f(x) = \text{sign} \left( \sum_{\text{support vectors}} y_i \alpha_i^0 (x_i \cdot x) - b_0 \right)$$

여기서  $x_i$  를 지지벡터(support vector)라고 하는데 이것은 최적화 과정을 통해서 얻어진 값 중에서 0 이 아닌 값을 이용해서 결정되고 기준치  $b_0$  는 다음 공식을



이용해서 구할 수 있다.

$$b_0 = \frac{1}{2} [(w_0 \cdot x^*(1)) + (w_0 \cdot x^*(-1))]$$

여기서  $x^*(1)$ 는 긍정 범주의 지지벡터,  $x^*(-1)$ 는 부정 범주의 지지 벡터를 의미한다(Vapnik 1999).

SVM에서는 동시에 여러 범주에 할당될 수 있는 데이터로 인한 오류 발생 등의 이유로 선형적으로 분리할 수 없는 경우에는 잘못 분류된 지점을 허용하는 완화 (slack) 변수  $\xi_i$  를 도입해서 일반화된 초평면(generalized hyperplane)을 구축하는 소프트 마진 분류기를 이용하게 된다. 이 때 초평면  $(w, b)$ 과 마진  $r$  상에서 데이터  $(x_i, y_i)$ 에 대한 완화 변수  $\xi_i$ 는 다음과 같이 정의된다.

$$\xi_i((x_i, y_i), (w, b), r) = \xi_i = \max(0, r - y_i(w \cdot x_i + b))$$

즉,  $\xi_i > r$ 가 될 경우 데이터  $(x_i, y_i)$ 는 잘못 분류된 것을 의미하며, 완화 변수  $\xi_i$ 는 얼마나 많은 데이터들이 초평면에서 마진  $r$ 의 범위를 벗어나 있는지를 측정하는 척도가 된다(Cristianini et al. 2000).

우수한 성능을 위해서는 마진폭과 학습오류의 수를 조정하여  $\xi_i \geq 0$  ( $i = 1, \dots, L$ ) 일 때  $y_i(x_i \cdot w + b) \geq 1 - \xi_i$  를 만족하는 범위에서 다음 수식에  $C$ 값을 최소화해야 한다(Cortes, and Vapnik 1995).

$$\tau(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L \xi_i$$

이를 라그랑주 승수  $\alpha_i$ 와 커널함수  $K(X, X_i)$ 를 이용하여 비선형 함수에까지 일반화하기 위해서는 다음 수식을 최대화하는 값을 찾는 최적화 문제가 된다. 아래의 식은  $0 \leq \alpha_i \leq C$  ( $i = 1, 2, 3, \dots, L$ ) 과  $\sum_{i=1}^l \alpha_i y_i = 0$  를 만족할 경우이다.

$$\max W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j (x_i \cdot x_j)$$

기준치  $b$ 는  $\alpha_i \leq C$ 인 모든 지지벡터에 대해서 완화 변수  $\xi_i$  값이 "0"이 되고 다음과 같이 표현할 수 있다(Scholkopf et al. 1999).

$$f(x) = \text{sign} \left( \sum_{i=1}^l y_i \alpha_i \cdot k(x, x_i) + b \right)$$

결국 완화 변수  $\xi_i$ 와 패널티 변수  $C$  값의 개념을 도입한 마진 분류기를 이용하게 되면 선형으로 분리할 수 없는 분류 문제의 경우도 어느 정도 해결할 수 있다(Coretes, and Vapnik 1995). 여기서  $C$  값은 마진폭과 분류 오류 사이의 타협점(trade-off)을 찾아주는 역할을 담당하며, 분리할 수 없는 데이터에 대한 오류 패널티 값을 의미한다. 선형적으로 분리할 수 없는 데이터에 대해서 마진 분류기를 이용하여 분류를 수행하게 되면 초평면에서 마진  $r$ 의 범위를 벗어나서 잘못 분류된 두 개의 데이터는 완화 변수  $\xi_i$ 와  $\xi_j$  값이 마진  $r$ 보다 큰 값을 갖게 되고, 제대로 분류된 그 밖의 다른 데이터들은 완화 변수 값으로 "0"을 갖게 된다.  $\xi_i$ 를 이용한 비선형 SVM 최대 마진 분류 평면은 그림 4-6에서 보여주고 있다.




그림 4-6  $\xi_i$ 를 이용한 비선형 SVM 최대  
마진 분류 평면

### 비선형 SVM

입력데이터의 선형 분리가 불가능할 경우 입력공간을 분리하는 비선형 결정면 (nonlinear decision surface)을 이용하게 된다. 함수  $K(X, X_i)$ 는 두 벡터의 내적을 나타내기 위한 커널 함수로 입력공간의 내적을 특징공간의 내적으로 변형시키는 역할을 한다. 이것은 특징공간으로 입력 벡터를 투영시킴으로써 내적에 대한 계산만을 필요로 하게 되어 고차원일 경우 계산상의 어려움을 덜 수 있다.

$$K(x, y) = (\theta(x) \cdot \theta(y))$$

즉, 벡터  $x$ 는  $\theta(\cdot)$ 를 통하여 특징공간으로 변형시켜 두 벡터의 내적으로만 계산이 이루어지게 된다.




그림 4-7 커널함수를 이용한 입력공간에서 특징 공간으로의 변형 방법

그림 4-7 는 커널 함수를 이용해서 입력데이터를 입력공간에서 특징 공간으로 변형시키고 변형된 공간에서 최대마진 분류평면을 적용한 것을 나타내고 있다.

일반적으로 사용되는 커널함수는 다항식(polynomial) 커널함수, RBF(Radial Basis Function) 커널함수, 다층 퍼셉트론(multi-layer perceptron) 커널함수 등이며, 본 연구에서는 아래의 커널함수를 이용하여 실험을 수행하였다.

#### 다항식 커널함수 (polynomial kernel function)

다항식 커널함수는 스칼라 곱(dot product)으로 처리되기 때문에 두 벡터간의 방향에 의존적이며, 결국 동일한 방향을 갖는 벡터들은 다항식 커널함수를 이용했을 때 높은 결과 값을 갖게 된다.

$$K(X, X_i) = ((X \cdot X_i) + 1)^d, \quad d \text{는 다항식의 차수를 나타낸다.}$$

RBF 커널 (radial basis function kernel)

$$f(x) = \text{sign} \left( \sum_{i=1}^N a_i K_r(|x - x_i|) - b \right)$$

여기서  $K_r(|X - X_i|)$  은 두 벡터 사이의 거리인  $|X - X_i|$ 에 영향을 받게 되고, 가장 일반적인 함수모형은 아래와 같다.

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right)$$

일반적으로 RBF 커널함수는 지지벡터와 검증 데이터간의 유클리드 거리와 연관되며, 여기서 지지벡터는 RBF의 중심점이 된다. 값이 커질수록 완만한(smooth) 결정면을 갖게 된다.

## 제 5 장 결 과

### 5.1 SAM을 이용한 실험자 주관평가 결과

표 5-1. 주관적으로 평가한 SAM 평가 결과와 평가에 의한 감정 상태

자극의 종류	평가의 종류	점수					평균점수	감정 상태
		-2	-1	0	1	2		
쾌	arousal	0	9	13	3	0	-0.24	상당히 편안한
	valance	0	0	7	11	7	1	대체로 행복함
불쾌	arousal	0	4	8	13	0	0.36	매우 흥분
	valence	18	7	0	0	0	-1.72	매우 불쾌

표 5-1. 는 실험이 끝난 후 25명의 실험자에게 SAM평가를 한 결과이다. 표 5-1. 는 실험자가 평가하는 감정상태에 점수를 할당하고 실험자 전체의 평균과 분포정도를 나타냈다. 감정유발영상을 보여준 후 주관적인 평가를 한 결과 쾌 자극에 대해서는 평균 Arousal이 -0.24로 편안한 감정상태로 나타났고 Valence는 1로 대체로 행복한(Happy) 상태로 나타났다. 그러므로 쾌 영상을 실험자에게 보여주었을 때 우리가 의도했던 긍정적인 반응을 얻었음을 알 수 있었다. 불쾌 영상에 대해서도 주관적인 평가를 한 결과 평균 Arousal이 0.36으로 약간 흥분된 상태로 나타났고 Valence는 -1.72로 매우 불쾌했던 것으로 나타났다. 그러므로 불쾌감정 유발영상 역시 실험자에게 보여주었을 때 의도했던 반응을 얻을 수 있었음을 나타내주고 있다.

## 5.2 감정상태에 따른 특징 파라미터 통계적 유의성 평가

표 5-2. 각 feature값에 따른 통계적 검증 (P value = 0.05)

	Feature1 (mean of EVs)	Feature 2 (median of EVs)	Feature 3 (Variance of RRI)	Feature 4 (mean of RRI)	Feature 5 (ZCC of GSR)	Feature 6 (mean of SKT)
유의성 여부	O	O	O	X	O	O
p value	0.0036	0.00092	0.00019	0.409	0.00359	0.000012

( EVs : Eigenvalues, RRI : RR interval, ZCC : Zero crossing Count, SKT : Skin Temperature )

특징을 추출한 각 파라미터에 대해서 통계적인 검증을 위해 T test를 진행했다. t-test(검정)는 두 집단간의 평균의 차이가 통계적으로 유의한지를 파악할 때 필요한 통계적 기법이다. 일반적으로, 두 집단의 평균을 비교하는 분석방법은 크게 Z-test와 t-test로 구분되는데 Z-test는 모집단의 분산을 알고 있는 경우에 사용된다. 그러나 실험자마다 개인적으로 차이가 있는 감성추출 특징파라미터의 분산을 알고 있는 경우는 없기 때문에 t-test를 사용한다.

Feature4를 제외한 모든 특징 파라미터에서 P value가 0.05 (신뢰수준 95%) 일 때 유의성을 만족했다. 이것으로 감정상태를 대변할 수 있는 값으로 추출된 파라미터의 유의 정도를 나타낼 수 있다. 두 가지 감성상태에 따라 대부분의 특징(feature1~ feature6)에서 유의성을 띄었으므로 검증된 특징벡터를 기반으로 감성상태를 추정/예측하려 한다.

## 5.3 패턴인식 알고리즘을 이용한 감정상태 검출 정확성 평가

### 5.3.1 선형분별함수(Linear Discrimination Function) 평가

표 5-3. 선형분별함수를 이용한 정확도 평가

	5 feature	6 feature
Test 1	0.67	0.80
Test 2	0.61	0.81
Test 3	0.65	0.74
Test 4	0.69	0.77
Test 5	0.66	0.78
<b>평균</b>	<b>0.66</b>	<b>0.78</b>

표 5-3. 는 각각의 특징벡터에 따른 정확도를 5 fold cross validation 해준 결과다. 선형분별함수를 이용해 나타난 결과는 5개의 특징을 추출한 벡터를 사용했을 때 평균 0.66의 정확도를 나타냈고, 6개의 특징을 추출한 벡터를 사용했을 때 평균 0.78의 정확도를 나타냄으로써 특징의 개수가 증가된 6개의 특징벡터 조합이 좀 더 좋은 성능을 나타냈다. 비선형적인 특징으로 나타난 감정추출 데이터는 선형분별함수를 통해 분석한 결과 정확도 측면에서는 전체적인 성능이 낮게 평가되었다. 이것은 계산과정에는 간단하다는 장점이 있으나 정확도를 고려해 볼 때 낮은 성능이 나타났기 때문에 비선형 패턴분석이 필요하다.



### 5.3.2 Reduced Model 평가

표 5-4. Order에 따른 Reduced Model을 이용한 정확도 평가 (5 feature)

	1order	2order	3order	4order	5order	6order	7order	8order	9order	10order
Test1	0.73	0.81	0.83	0.82	0.85	0.83	0.85	0.85	0.88	0.63
Test2	0.64	0.75	0.79	0.77	0.8	0.82	0.82	0.8	0.8	0.82
Test3	0.65	0.75	0.77	0.81	0.85	0.84	0.88	0.88	0.86	0.87
Test4	0.75	0.78	0.8	0.81	0.8	0.81	0.83	0.82	0.86	0.88
Test5	0.66	0.71	0.69	0.78	0.76	0.78	0.8	0.79	0.82	0.79
<b>평균</b>	<b>0.69</b>	<b>0.76</b>	<b>0.77</b>	<b>0.8</b>	<b>0.81</b>	<b>0.82</b>	<b>0.84</b>	<b>0.83</b>	<b>0.84</b>	<b>0.8</b>

표 5-5. Order에 따른 Reduced Model을 이용한 정확도 평가 (6 feature)

	1order	2order	3order	4order	5order	6order	7order	8order	9order	10order
Test1	0.8	0.85	0.88	0.9	0.91	0.92	0.95	0.92	0.93	0.86
Test2	0.8	0.8	0.81	0.84	0.85	0.91	0.91	0.9	0.94	0.9
Test3	0.75	0.76	0.83	0.85	0.86	0.91	0.92	0.92	0.9	0.91
Test4	0.79	0.83	0.87	0.89	0.9	0.94	0.94	0.95	0.94	0.95
Test5	0.76	0.85	0.86	0.87	0.89	0.92	0.93	0.93	0.94	0.93
<b>평균</b>	<b>0.78</b>	<b>0.82</b>	<b>0.85</b>	<b>0.87</b>	<b>0.88</b>	<b>0.92</b>	<b>0.93</b>	<b>0.93</b>	<b>0.93</b>	<b>0.91</b>

표 5-4. 와 표 5-5. 는 order에 따른 Reduced Model의 정확도를 평가하고 있다. 상대적으로 높은 차수(Order)의 Reduced Model이 높은 정확도를 나타냈고 비선형적인 특성을 구별해낼 수 있으며, 6 feature가 5 feature보다 전반적으로 높은 성능을 나타내고 있었다. 차수를 증가시키면서 정확도를 평가했고 5 feature와 6 feature들 다 9 order 일 때 가장 높은 성능을 나타냈다. 이것으로 심전도에 대한 주성분분석의 결과 중간 값(median)이 감성을 대변하는 데이터로 적당하다는 것

을 나타내준다. 차수가 높으면 높을수록 정확도는 높아지지만 계산 복잡도가 동시에 높아지게 된다. 10 order보다 높은 차수의 다항식을 적용하는 것은, 차수와 계산 복잡도는 비례 관계임으로, Reduced model에 적용 의미가 없다고 판단하고 1~10 order정도의 차수를 변형시키면서 적합한 차수를 평가해보았다.




그림 5-1. Order에 따른 Reduced Model을 이용한 정확도 평가  
(5 feature, 6 feature)

그림 5-1. 에서는 각 특징조합과 차수에 따른 정확도 결과를 보기 쉽게 그래프로 나타냈다. 두 개의 특징 모두 order가 10차 이상일 때 성능(정확도)이 감소하는 특성을 나타냈다. 동일한 신호에서 특징을 추가한 6 feature가 높은 성능을 보이는 것으로 pre\_processing 신호처리 과정의 중요성을 시사해 주고 있다. 감성상태를 좀더 잘 나타나게 해주는 필터 설계가 중요한 변수가 될 것으로 기대된다.

### 5.3.3 신경회로망(Neural Network: Multilayer Perceptron) 평가

표 5-6. 신경회로망을 이용한 정확도 평가 (5 feature, 6 feature)

	5 feature	6 feature
Test1	85.8	93.9
Test2	89.3	88.8
Test3	87.8	91.4
Test4	86.1	93.2
Test5	86.5	93.6
<b>평균</b>	<b>87.1</b>	<b>92.2</b>

비선형적인 패턴인식에서 신경회로망은 보편적인 추정기(universal approximator)로 알려져 있다. 신경회로망의 학습방법 중에는 Error back propagation 알고리즘(Rumelhart et al. 1986)을 선택해 학습했다. Error back propagation 학습은 구하고자 하는 이상적인 출력과 실제출력과의 오차를 최소화하기 위한 방법으로 기울기 하강법 (gradient descent)으로 학습을 한다.

생체 신호로부터 추출된 정규화 입력벡터를 입력 층, 은닉 층 및 출력 층으로 구성된 신경회로망 (MultiLayer Perceptron) 에 학습 시켰다. 활성화함수로는 시그모이드 함수를 사용하였고 출력벡터와 목표벡터의 오차가 Fletcher가 제시한  $10^{-4}$ 보다 작을 때까지 반복학습(Iteration) 했다. 이때 반복학습은 불필요하게 많은 학습으로 네트워크의 가중치 값이 Overfitting되지 않도록 3000번으로 제한을 두었다.

대부분의 패턴인식 연구에서 신경회로망의 성능은 뛰어나지만, 본 연구에 쓰이는 감성추출 데이터의 양은 유한하며, 추정하고자 하는 목적함수 (objective function) 의 분포를 효과적으로 반영하지 못해 정확도가 낮을 수 있다는 문제점을 가지고 있다.

그 결과 5 feature에서 평균 87.1%의 정확도를 나타냈으며 6 feature에서 평균 92.2%의 정확도를 나타냈다. 안정적으로 훈련되었을 때 비교적 높은 정확도를 나타내고 있으며 5 fold cross validation을 통해 독립된 그룹으로 테스트해 본 결과 역시 평균에 근접한 결과를 나타냈다. 신경회로망은 다양한 사람에 의한 결과의 변수가 다양할 때 적용하면 좀 더 좋은 결과를 보여줄 것으로 기대하고 있다.

### 5.3.4 RBF kernel을 이용한 SVM 평가

표 5-7. SVM을 이용한 정확도 평가 (5 feature, 6 feature)

	5 feature	6 feature
Test1	100	96.99
Test2	100	100
Test3	100	95.69
Test4	100	97.74
Test5	98.87	97.6
<b>평균</b>	<b>99.77</b>	<b>97.61</b>

지금까지 선형분별함수, Reduced model, 신경회로망의 성능을 평가했다. 그 중 신경회로망이 가장 좋은 성능을 나타냈지만 신경회로망 역시 95%이상의 정확도를 나타내주지 않기 때문에 실제 감정판별에 대해 적용하기에는 아직까지는 부족한 면이 있다. 이렇듯 대부분의 전통적인 statistical learning method들이 가진 단점을 보완해 줄 수 있는 방법이 SVM이다[Vapnik 1995].

여러 사람을 대상으로 감성데이터를 추출했고 추출된 데이터를 바탕으로 패턴을 분석하는데 좀더 많은 데이터를 추출한 6 feature의 값이 다른 알고리즘에서는 높은 성능을 나타냈지만 SVM에서는 그렇지 않은 결과를 나타냈다. 이것은 training을 어떻게 하는가에 대한 문제다. 최대분류마진을 구할 때 C값을 설정해주는데 feature가 증가하면 C값도 증가시키는 것이 원칙이다. 하지만 계산의 복잡도도 C의 값이 증가함에 따라 증가되기 때문에 C값을 고정시키고 training을 해주었다. 그리고 SVM은 kernel에 의해 그다지 큰 영향을 받지 않는다고 알려져 있기 때문에 RBF Kernel의 선택은 SVM의 성능 차이에 그다지 큰 차이를 가져오지 않는 것으로 가정하고 정확도를 테스트했다.[Saunders 1998].

SVM을 통해 나타난 결과는 5 feature일 때 99.77%의 정확도를 나타냈고 6 feature일 때 97.61%의 정확도를 나타냈다. 상대적으로 5 feature의 정확도가 높은 것은 training의 복잡도 문제고 결과에 큰 영향을 주지 않는다. SVM의 결과는 감성추출 데이터에 대한 추출 능력평가에서 95%의 정확도를 나타냈다는 것에 의의가 있다.

### 5.3.5 4가지 알고리즘에 대한 전체적인 성능 평가




그림 5-2. 두 개의 feature set에 따른 각 알고리즘의 평균적인 성능평가  
LDF :선형분별함수, RM : Reduced model, NN :Neural network

표 5-8. 두 개의 feature set에 따른 각 알고리즘의 평균적인 성능평가

	5 feature	6 feature
LDF	66.1	78.2
RM	79.6	88.2
NN	87.1	92.2
SVM	99.8	97.6

표 5-8. 와 그림 5-2. 는 두 개의 feature 형태와 각 알고리즘에 대한 정확도를 평가한 것이다. 전반적인 알고리즘의 성능을 내림차순으로 정리하면 SVM > 신경회로망 > Reduced model > 선형분별함수 순서로 정확도를 나타냈다. 각 알고리즘

의 성능 평가값은 5 fold cross validation해준 평균값을 나타낸 것이고 100에 가까울수록 좋은 성능을 나타낸 것이다. 생체신호를 이용해 두 가지 감정상태에 따른 추출된 특징 값들은 non stationary하고 비선형적인 특징을 나타냈다. 그러므로 비선형적인 패턴분석에 탁월한 SVM, 신경회로망, Reduced model 이 선형분별함수보다 평균적으로 높은 분별능력을 나타냈다.

전통적으로 비선형적인 특성분석에 훌륭한 성능결과를 나타내는 신경회로망은 SVM 보다 낮은 결과를 나타냈다. 하지만 현재 가지고 있는 데이터의 개수보다 샘플데이터 개수가 더 많아지고 좀더 다양한 사람에게 적용 가능한 알고리즘 선정에 있어 SVM이 가장 좋다고 단정 지어 말할 수 없다. 왜냐하면 좀더 다양하고 큰 데이터를 분류하는데 신경회로망이 좀더 탁월한 성능을 나타낼 수 있기 때문이다.

### 5.3.6 파라미터 선택에 의한 4가지 알고리즘 정확도 평가

표 5-9. 파라미터의 선택적 조합에 따른 4가지 알고리즘 정확도 성능평가 결과

	파라미터 조합												
	a	b	c	d	e	f	g	h	i	j	k	l	m
F1	o	o	o	o	o	o	o	o	x	x	o	x	x
F2	o	o	o	o	o	o	o	x	o	x	x	o	x
F3	o	o	o	o	x	x	x	x	x	o	x	x	x
F4	o	o	o	x	o	x	x	x	x	o	x	x	x
F5	o	o	x	x	x	o	x	o	o	x	x	x	o
F6	o	x	x	x	x	x	x	x	x	x	x	x	x
LDF	77.9	66.0	64.6	64.6	73.1	64.9	72.8	61.9	64.1	55.6	59.5	62.9	57.2
RM	93.0	87.8	95.5	94.4	87.1	87.5	86.0	68.9	76.2	72.3	68.0	69.8	57.2
NN	92.2	91.4	88.8	86.3	77.9	75.7	75.9	73.5	73.4	53.2	64.7	66.6	68.6
SVM	100	90.3	87.6	87.6	82.2	85.6	82.2	71.4	79.9	59.6	61.9	70.8	65.7

( F1 : Eigenvalues의 평균값, F2 : Eigenvalues의 중간값, F3 : RR interval의 분산값, F4 : RR interval의 평균값, F5 : GSR 의 특징값, F6 : SKT의 특징값 )

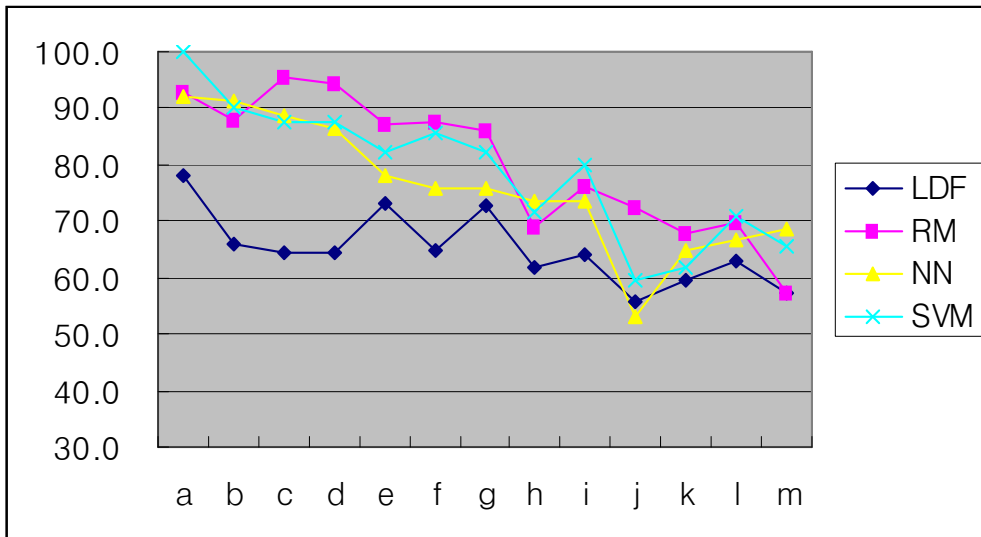


그림 5-3 파라미터의 선택적 조합에 따른 4가지 알고리즘 정확도 성능평가 결과

표 5-9. 은 파라미터의 조합을 6개에서 1개로 줄이면서 적합한 파라미터 선정에 대한 결과를 보이려 한다. 기록되어 있는 모든 조합은 5 fold cross validation을 해주었으며, 전반적으로 SVM과 Reduced model이 높은 정확도를 나타냈다. 가장 높은 정확도를 나타낸 조합은 a 가 나타냈으며, 가장 낮은 정확도를 나타낸 조합은 j, k, l, m 이다. 파라미터 조합 j에서 정확도의 값이 크게 낮아지는 것을 볼 수 있는데 RR 간격의 평균값과 RR 간격의 분산값의 조합은 감정상태를 나타내는데 큰 도움을 주지 않는다는 것을 의미한다. 그리고 파라미터 조합 b에서 역시 정확도가 크게 떨어지는 것을 볼 수 있는데, 이것은 피부온도는 감정상태를 대변하는 파라미터로 영향력이 있음을 나타낸다. 하지만 실험자에게서 불쾌감상태일 때 피부온도가 올라가는 것이 생리학적으로 뚜렷하지 않았기 때문에 불쾌감상태일 때 피부온도가 올라간다 말하기 힘들지만 파라미터 조합측면에서 볼 때 피부온도는 영향력 있는 파라미터다.

모든 파라미터 조합에서 파라미터의 수가 적으면 적을수록 정확도는 떨어지는 경향을 나타냈으며 많은 수의 파라미터 조합 a, b 와 i, j 등의 경우를 제외하고 다른 대부분의 조합에서 Reduced model에서 높은 성능을 나타냈다. 평균적으로 가장 높은 정확도를 나타낸 알고리즘은 SVM이고 조합 가능한 파라미터의 전반적인 성능 평가에서는 Reduced model이 높은 성능을 나타냈다.

신경회로망의 정확도 평가의 경우에는 가장 높은 정확도일 때가 92% a 로 나타났고 가장 낮은 정확도일 때는 68.6% m 으로 나타났다. RR 간격의 평균값과 RR



간격의 분산값의 조합은 높은 성능을 나타내기에 불충분한 조합으로 판명되었다. 하지만 이 두개의 파라미터가 전혀 쓸모없는 조합은 아니다. 왜냐하면 조합 b와 조합 f의 성능을 비교해 볼 때, 조합 b의 성능이 전반적으로 우수하기 때문이다. SVM, 신경회로망, Reduced model로 알고리즘을 성능평가 할 때 조합 a, b, c, d가 탁월한 성능을 나타내고 있지만, 조합 a, b, c, d는 주성분 분석과정이 들어간 파라미터가 두개씩 있기 때문에 계산과정(computational complexity)이 복잡하다는 단점이 있다. 계산과정이 복잡하다는 것은 유비쿼터스 시대에 감정판별 파라미터로 사용되는 것에 대한 어려움이 있다. 그래서 모든 알고리즘에서 정확도가 70%이상의 성능을 나타내면서 파라미터 선택에 계산량의 관계를 trade off한 조합인 조합 g를 권장한다.

## 제 6 장 결 론

본 연구의 목적은 생체신호를 이용해 감정상태를 추정하는데 있어 최적의 감성과 파라미터의 조합과 정확도와 계산 복잡도를 trade off하는 최적의 파라미터 선정에 있다. 감성유발이 이루어진 생체데이터를 얻기 위해 자극적인 실험동영상을 이용했으며, 자극에 따른 설문 평가를 SAM을 이용해서 얻을 수 있었다. Lang에 의해 고안된 SAM평가는 실험자에게 얻어진 데이터가 정말 감정이 유발된 데이터인지 아닌지에 대한 판단기준으로 작용했으며, 자극에 대한 반응정도에 대한 기준으로 작용되어 감성자극 실험에 유용한 설문지로 사용되었다. 목적하는 감정반응과 자극동영상의 성격이 거의 일치했음을 결과에서 보이고 있다.

생체신호를 이용한 감정데이터 추출에 있어, 측정하고 있는 3가지 데이터는 비교적 측정하는 조건이 까다롭지 않았고, 실험자는 측정 시 불편함을 거의 느끼지 못했다. 본 연구는 순간적인 감정상태변화를 정확하게 검출하는데 목적이 있기 때문에 전처리 과정이기도 한 생체신호 특징추출 부분은 전체 알고리즘이 좌우되는 가장 중요한 부분이라 할 수 있다.

감정추정 결과에 따르면, 생체신호에서 좀 더 많은 특징 값을 뽑아내면 낼수록 대부분의 추정 알고리즘의 정확도는 증가하는 경향을 나타냈다. 특히 심전도에서 감정데이터를 추출하는 과정 중, median 필터의 성능은 mean 필터의 성능 보다 우수함을 나타냈으며 두개의 특징 값을 같이 사용했을 때 좀 더 높은 성능을 나타냈다. 심전도의 신호처리 과정은 순간적인 감정의 변화를 검출하는데 초점을 두었기 때문에 모든 감정을 추정하는 application에 적용하기는 부적합하다. 그리고 실사용을 위한 감정상태를 추정하기 위해서 쾌/불쾌 상태뿐만 아니라 보통상태에 대한 평가 역시 필요하다. 왜냐하면 인간의 감정상태를 나타낼 때 복합적인 여러 감정 상태 중 가장 그 당시를 대변할 수 있는 하나의 감정상태를 말하게 되는데, 특

별한 감정이 유발되지 않은 상태일 때 대부분의 보통상태로 정의하기 때문이다. 이것은 실사용 application에서 유용하게 사용될 것으로 보인다.

이 연구에서 얻어진 결과로 감성반응 형 유비쿼터스 서비스를 실현시키기 위한 생체신호 파라미터 선택을 목적으로 한다고 가정하겠다. 그러면 감성반응 형 유비쿼터스 환경에 적합한 하드웨어 디바이스는 저 전력, 경량을 요구하기 때문에 감성유발 파라미터를 검출하는데 복잡한 계산이 들어간 알고리즘은 많은 전력을 요구하기 때문에 부적합하고, 생체신호 취득하는데 여러 개의 파라미터는 정확도를 높일 수 있으나, 인간의 활동을 제약하기 때문에 부적합하다. 그래서 정확도와 생체 파라미터의 선정은 적당한 trade off가 요구된다.

본 연구에 사용된 각 파라미터는 손쉽게 측정가능하며, 결과로서 간단한 생체신호의 측정만으로 감성 반응 형 유비쿼터스 서비스를 제공하는 핵심 기술로 활용 가능함을 말해주고 있다. 더 나아가 이와 같은 연구의 활용분야로 의료, 게임, 가상 현실 등 분야에서 폭넓게 사용될 것으로 기대되고 있다.

## 참 고 문 헌

- [1] Rosalind W. Picard, Elias Vyzas, Jennifer Healey: Toward Machine Emotional Intelligence: Analysis of Affective Physiological State, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 23, No. 10. October (2001)
- [2] R.Sinha O. Parsons: Multivariate response patterning of fear and anger, Cognition and Emotion, Vol. 10, no. 2, pp. 173-198, (1996)
- [3] Lang P J, Bradley, M.M & Cuthbert, B.N NIMH: Center for the Study of Emotion and Attention, "international Affective Picture System (IAPS)" Technical Manual and Affective Ratings (1995)
- [4] Christine Laetitia Lisetti, Fatma Nasoz.: Using Noninvasive Wearable Computers to Recognize Human Emotions from Physiological Signals, EURASIP Journal on Applied Signal Processing, 11, 1672-1687 (2004)
- [5] Jiapupan and Willis J. Tompkins: A Real Time QRS Detection Algorithm, IEEE Transactions on Biomedical Engineering Vol. BME-32, No. 3, March (1985)
- [6] Mika P. Tarvainen, Perttu O. Ranta-aho, and Pasi A. Karjalainen: An advanced detrending method with application to HRV analysis, IEEE Trans Biomed Eng, 49(2): 172-175, (2002)
- [7] R.W. Levenson, P. Ekman, and W.V. Friesen: Voluntary facial action generates emotion-specific autonomic nervous system activity, Psychophysiology, Vol. 27, pp.363-384 (1990)
- [8] John T. Cacioppo, Gary G. Berntson, Jeff T. Larsen, Kirsten M. Poehlmann, Tiffany A. Ito " The psychophysiology of Emotion "The handbook of emotion, 2nd. Edition (pp. 173-191). New York: Guilford Press
- [9] Andreassi, J. L Psychophysiology human behavior and physiological

- response, Lawrence Erlbaum Associates, New Jersey (2000)
- [10] F. Wang, K. Sagawa, H. Inooka, : Time domain HRV index for assessment of Dynamic stress, Computers in Cardiology (1998)
- [11] K.H. Kim, S.W. Bang, S.R. Kim: Emotion recognition system using short-term monitoring of physiological signals, Medical & Biological Engineering & Computing, Vol. 42, 419-427 (2004)
- [12] R.W. Picard, Affective Computing, MIT Press, London, England, (1997)
- [13] Yoon-Ki Min, Soon-Cheol Chung, Byung Chan Min (2005) Physiological Evaluation on Emotional Change Induced by Imagination. Psychophysiology and Biofeedback, Vol. 30, No 2, June 2005
- [14] Sun. K. Yoo et al,(2005) Neural Network Based Emotion Estimation using Heart Rate Variability and Skin Resistance, ICNC 2005 LNCS 3610, pp 818-824, 2005
- [15] Shusterman, V., Barnea, O.(1995) Analysis of skin-temperature variability compared to variability of blood pressure and heart rate, IEEE Ann Conf. Engineering Medicine Biology Society, pp 1027-1028
- [16] Task Force of The European Society of Cardiology and The North American Society of Pacing and Electrophysiology: Heart rate variability, Standards of measurement, physiological interpretation, and clinical use, American Heart Association Inc. European Society of Cardiology (1996)
- [17] Boucsein W. Electrodermal activity, Plenum Press, New York (1992)
- [18] Shusterman, V., Barnea, O.: Analysis of skin-temperature variability compared to variability of blood pressure and heart rate, IEEE Ann Conf. Engineering Medicine Biology Society, pp 1027-1028 (1995)
- [19] Anil K. Jain, Jianchang Mao, K.M. Mohiuddin.: Artificial Neural Networks A tutorial, IEEE Computer Society, Vol. 29, No. 3 ,March 1996
- [20] Richard O. Duda(et): Pattern Classification, Second Edition, A Wiley-Interscience Publication (2001)

- [21] K. Hornik, M. Stinchcombe, and H. White.: Multilayer feedforward networks are universal approximators. *Neural Networks*, 2:359--366, (1989)
- [22] Rumelhart, D.E., Hinton, G.E., Williams, R.J.: Learning internal representations by error propagation. *Parallel Data Processing, Vol.1* The M.I.T. Press, Cambridge, 318--362, (1986)
- [23] Fletcher R. (1987) *Practical Methods of Optimization* (Second edn.). New York: John Wiley
- [24] V. Vapnik : *Estimation of Dependencies Based on Empirical Data*, Springer-Verlag, New York, (1982)
- [25] C.J.C. Burges : *A Tutorial on Support Vector Machines for Pattern Recognition, Data Mining and Knowledge Discovery* (1998)
- [26] C. Saunders, M. O. Stitson, J. Weston, L. Bottou, B. Scholkopf, and A. Smola.: *Support vector machine reference manual*. Technical Report CSD-TR-98-03, Royal Holloway, University of London, Egham, UK, (1998)
- [27] 정기삼, 이병채, 하은호, 김동윤, 김동선: 감성완구 제작을 위한 감성분석 시스템 개발에 관한 연구, 한국감성과학회: 학술대회지, 한국감성과학회 01 추계 학술대회 논문집, pp.239-244, 2001
- [28] The Principles of Software QRS Detection, Reviewing and Comparing Algorithms for Detecting this Important ECG Waveform, *IEEE ENGINEERING IN MEDICINE AND BIOLOGY* January/February 2002
- [29] P.S. Hamilton and W.J. Tompkins,: Quantitative investigation of QRS detection rules using the MIT/BIH arrhythmic database, *IEEE Trans. Biomed. Eng.*, vol. 33, pp. 1157-1165, 1986.
- [30] M. Patel: Colouration Issues in Computer Generated Facial Animation, *Computer graphic forum*, Volume 14, (1 995) number 2 pp. 117-126

## ABSTRACT

### A Study of Emotional State Detection Algorithm using Bio-signal

Lee, Chung Ki

Dept. of Electrical Engineering

The Graduate School

Yonsei University

The goal of this thesis is to develop the emotional state detection algorithm which responds according to user's emotions. For this, we tried to distinguish emotions of human using biosignal parameters of ANS(Autonomous Nervous System). Why we especially focused on ANS is that ANS can not be adjusted by one's will and can reflect the changes in emotions. So we selected GSR, HRV and SKT as representative parameters which show the changes in ANS among many parameters of ANS. 25 subjects were participated for the Emotion-Experiment. We chose some video materials which can induce negative emotion or positive emotion from the supine subject and measured GSR, HRV and SKT while they are watching that materials. The data from those three parameters GSR, HRV and SKT were segmented and we analyzed and extracted the features of each segment. The results showed that there is a big difference between the positive and negative emotions. This paper shows that we can exactly distinguish two emotions using a few biological parameters.

---

Key words : Detection of Emotional State, Bio-signal, Algorithm Evaluation