

SES ÖZNİTELİK VEKTÖRLERİNİN DUYGUSAL DURUM SINIFLANDIRILMASINDA KULLANIMI

Gökhan POLAT¹

Halis ALTUN²

^{1,2}Elektrik Elektronik Mühendisliği Bölümü, Mühendislik Mimarlık Fakültesi

Niğde Üniversitesi, 51200 NİĞDE

¹e-posta: gpolat51@yahoo.com

²e-posta: haltun@nigde.edu.tr

ABSTRACT

Recognition of emotion in human speech is a highly active research area, which has attracted the interest of research community. Although, a large amount of research has been conducted to determine which aspects of the speech signal are more informative in emotion detection, it is still an open-ended problem to identify reliable discriminating features for this task. In this paper, an attempt to discern the informative power of each individual speech-related feature in emotion detection is carried out using artificial neural network approach.

Anahtar sözcükler: Ses Analizi, Yapay Sinir Ağı, Duygusal Durum Tespiti

1. GİRİŞ

Yaşanan teknolojik gelişmelere paralel olarak insan bilgisayar etkileşiminin hızlı bir şekilde artmakta olduğu gözlemlenmektedir. İnsan-bilgisayar etkileşiminin güçlendirilmesi, kullanıcı ve bilgisayar arasında şu anda var olan bilgi alışverişinin ötesinde yeni etkileşim kiplerinin gerçekleştirilmesini gerektirmektedir. Bu bağlamda kullanıcının duygusal durumunun bilgisayar tarafından tespit edilebilmesi insan-bilgisayar etkileşimi güçlendirecektir. Bu ihtiyaca paralel olarak insan sesini kullanarak duygu sınıflandırma son yıllarda üzerinde yoğun olarak çalışılmakta olan bir konu haline gelmiştir [1-6]. İnsanın içinde bulunduğu duygusal duruma bağlı olarak fizyolojik parametrelerin değişim gösterdiği bilinmektedir. Nabız sayısı, kan basıncı, yüz mimikleri, el ve kol hareketleri, ses, beyin dalgaları, hormonal değişiklikler vb. parametreler ruh hallerine göre farklılık göstermektedir. Ses kişinin duygusal durumunu dışa vurmasında %38'lik bir oranla yüz işaretlerinden sonra ikincil öncelik taşımaktadır [7]. Bunun yanında ses özniteliklerinin diğer özniteliklere göre kayıt edilip incelenmesi diğer parametrelere göre oldukça kolaydır.

Duygusal durum sınıflandırma problemi temel olarak bir sınıflandırma problemi olduğundan duygu sınıflandırma örüntü tanıma problemi olarak ele alınabilir. Bir örüntü tanıma işlevi olarak otomatik duygu sınıflandırma, en azından üç alt bileşen

içermelidir. Özniteliklerin belirlenmesi ve elde edilmesi, öznitelik seçimi ve sınıflandırıcılar. Bu çalışmada ses öznitelik vektörlerinin yapay sinir ağları yardımı ile duygu sınıflandırma probleminde kullanımı ele alınacaktır.

2 - VERİ SETİ

Literatürde duygusal durum sınıflandırma çalışmalarında çok farklı sayıda ve kombinasyonda duygusal durum ile çalışıldığı görülmektedir. Literatürde rastlanan çalışmalarda;

a-Doğallık, neşe, can sıkıntısı, üzüntü, öfke, korku [8],

b-Öfke, korku, üzüntü, neşe ve tikslenme [9],

c-Doğallık, mutluluk, can sıkıntısı, üzüntü, öfke, korku ve tikslenme [10],

d-Mutluluk, şaşırma, alay, üzüntü, öfke, korku, doğallık ve tikslenme [11],

e-Kızgınlık, sıkıntı, mutluluk, üzüntü ve doğallık [12],

f-Mutluluk, üzüntü, öfke, tikslenme, ve korku [13]

gibi duygu kombinasyonları duygusal durum tespitinde kullanılmıştır.

Literatürde üzerinde en çok çalışılan ve 4 temel duygu olarak kabul edilen [13] kızgınlık, mutluluk, normal ve üzüntü ruh hallerinin sınıflandırılması bu çalışmanın amacı olarak belirlenmiştir. Bu amaç doğrultusunda Berlin veri seti kullanılmıştır [14]. Berlin veri seti 5 erkek ve 5 bayan olmak üzere toplam 10 kişi tarafından 10 farklı cümle söylenerek seslendirilmiştir. Bu veriseti seçilen duygu durumları için toplam 337 ses kaydı içermektedir. Bu kayıtların işlenmesi sonucunda herbiri için 38 öznitelik vektörlerine sahip bir veri seti oluşturulmuştur.

3- ÖZNİTELİKLERİN BELİRLENMESİ

Duygusal durum sınıflandırma işleminin başarımı veri setlerinden elde edilecek öznitelik vektörlerinin sınıf özelliklerini en iyi şekilde temsil edebilmesine bağlıdır. Öznitelik vektörlerinin iyi belirlenmesi ve seçilmesi Duygusal Durum tespitinin başarısını arttıracaktır. [15-16].

Perde frekans bilgisi (F0) duygusal durum tespit çalışmalarında oldukça yoğun olarak kullanılmaktadır. Perde frekansının ortalama değeri, standart sapması, değişim aralığı vb. değerler duygu durum tespit çalışmalarında sıkça kullanılan özniteliklerdendir [17]. Muhammed Wgas Bhatti ve arkadaşları [15] yaptıkları

çalışmada perde frekansı ile ilişkili 11 öznelik vektörü çıkartılmışlardır. Bu öznelik vektörleri daha sonra duygusal durum tespit çalışmalarında kullanılmıştır. Perde frekansı, ses üretim mekanizmasında ses üretimi için ses tellerinde oluşan yarı-periyodik titreşim tarafından belirlenir [18]. Duygusal durum tespit çalışmasında genellikle perde frekansı ayırt edici bir öznelik vektörü olarak kullanılmıştır. Farklı duygu kipleri için perde frekansına ($F0_a$) ait özneliklerin değişim karakteristiği literatürde verilmiştir. Perde frekansı mutluluk, korku ve utangaç ruh halleri için benzer özelliklere sahiptirler; bu duygu durumları için $F0$ yüksektir ve belirgin ani değişimler gözlenmez [19]. Kızgınlık, korku ve mutluluk ruh halleri için ortalama $F0$ diğer ruh hallerine göre daha yüksektir [20-23]. Üzüntü ve sıkıntı ise en düşük $F0$ değerlerine sahip olan ruh halleridir [23,24].

Perde frekansı bilgisi kepsrum yöntemi kullanılarak elde edilmiştir. Bu yöntemde ses işareti ilk olarak pencereleme işlemine tabi tutulur ve sonra pencerelenmiş ses işareti üzerinde Ayırık Fourier Dönüşümü gerçekleştirilir. Frekans düzleminde logaritma uygulanır ve Ters Ayırık Dönüşümü alınarak Kepsrum katsayıları elde edilir. İşaret üzerinde frekans düzleminde uygulanan logaritma işlemi, ses yolu özellikleri ile ses kaynağı özelliklerinin ayrıştırılması olarak yorumlanabilir. Bu anlamda bir işaret ayrıştırması (deconvolution) gerçekleştirilmektedir. Ters AFD uygulandığında ses yolu ve ses kaynağına karşılık gelen özneliklerin ayrıştırılması işlemi tamamlanmış olur. Elde edilen ilk tepe noktası perde frekansının belirlenmesinde kullanılır.

Ses işaretlerinde perde frekansı eğrileri elde edildikten sonra perde frekansı bilgisi kullanılarak toplam 17 öznelik elde edilmiştir. Perde frekansı eğrisinden çıkartılan vektörler şu şekildedir:

1-Perde frekansı maksimum değeri: Perde frekansı eğrisinin aldığı en yüksek değerdir. Ruh hallerine göre farklılık göstermektedir. Mutluluk, korku ve kızgınlık ruh halleri için perde frekansı değeri diğer ruh hallerine göre daha yüksektir [20-23]. Perde frekansı maksimum değeri bu ruh hallerinin belirlenmesinde önemli bir özneliktir. Perde frekansı maksimum değeri (1) denklemi ile belirlenmiştir.

$$F0_{\max} = \max_j (F0_j) \quad (1)$$

2-Perde frekansı minimum değeri: Perde frekansı eğrisinin aldığı en düşük değerdir ve denklem (3) ile hesaplanır.

$$F0_{\min} = \min_j (F0_j) \quad (2)$$

3-Ortalama perde frekansı değeri: Elde edilen perde frekans değerlerinin ortalamasıdır. Bütün perde frekansı değerlerinin aritmetik ortalaması olarak (3) denklemi ile hesaplanır.

$$F0_{\text{ort}} = \frac{1}{n} \sum_{i=1}^n F0_i \quad (3)$$

4-Perde frekansı standart sapma değeri: Perde frekansı değerlerinin standart sapmasıdır ve duygu sınıflandırma probleminin çözümünde sıkça kullanılan önemli bir öznelik olarak görülmektedir. Bu değer (4) denklemi kullanılarak hesaplanmıştır.

$$\left[\frac{1}{n} \sum_{i=1}^n (F0_i - F0_{\text{ort}})^2 \right]^{\frac{1}{2}} \quad (4)$$

5-Perde frekansı maksimum bölgesi: Bu öznelik perde frekans ortalamasının üzerinde kalan bölgeyi ifade etmektedir ve ilk olarak bu çalışmada kullanımı önerilmektedir. Perde frekansı maksimum bölgesinin tanımı aşağıda denklem (5) tarafından verilen kritere göre yapılmıştır

$$F0_{\max-b} = \{ F0_i \mid F0_i \geq F0_{\text{ort}} \} \quad (5)$$

Bu işlem ile yeni bir bölge elde edilir. Böylelikle perde frekansı maksimum öznelik vektöründen daha kararlı bir öznelik elde edilmesi beklenmektedir. Bu alanda ortalama ve standart sapma hesapları yapılarak elde edilen değerler öznelik olarak kullanılacaktır.

6-Perde frekansı minimum bölgesi: Benzer bir şekilde kullanımı önerilen yeni bir öznelik olarak ortalama perde frekansı değerinin altında kalan bölgeyi temsil etmektedir. Bu bölgede ortalama ve standart sapma hesapları yapılır. Bu bölge (6) denklemi tarafından belirlenen kriter ile tanımlanır.

$$F0_{\min-b} = \{ F0_i \mid F0_i \leq F0_{\text{ort}} \} \quad (6)$$

7-Süre değeri: Bir cümle içerisinde sesli kısımların süresinin sessiz kısımlarının süresine oranı olarak tanımlanmıştır. Bu öznelik perde frekansı eğrisindeki sesli olmayan kısımların süresinin tüm eğrinin süresine oranı olarak kolayca belirlenebilir. Birçok çalışmada önemli bir öznelik vektörü olarak kullanılmıştır [13,18,21,22]. Mutluluk, tiksinti ve şaşkınlık uzun süreye sahip ruh halleridir. En uzun süre ise kızgınlık duygusu için belirlenmiştir [19].

8-Perde frekans eğrisinin türevi: Literatürde perde frekansının türevi ilgili bir özneliklerin belirlenmesi için kullanılmıştır [15]. Perde frekansı eğrisinin türevi alınarak yeni bir eğri elde edilir. Elde edilen eğrinin artan ve azalan kısımlarındaki maksimum, minimum, ortalama ve standart sapma değerleri öznelik olarak kullanılır.

9-Mel-Frekans Katsayıları (MFCC): Perde frekansı ile ilgili özneliklerin yanı sıra Mel-frekans katsayıları (MFCC) duygusal durum tespit çalışmalarında sıkça kullanılmaktadır [13,16,22]. MFCC süzgeç bankası spektrumunun ayırık kosinüs dönüşümünün alınması ile elde edilir. Toplam 16 Mel-frekans katsayısı elde edilmiştir.

10-Altband Enerji Değerleri: Sık rastlanmasa da alt bant enerjilerinin öznel olarak kullanımı duygusal durum tespit çalışmalarında görülmektedir [16]. Bu çalışmada alt-bant enerjisini elde etmek için 6. dereceden eliptik filtrelerden oluşan 5 bantlı bir filtre bankası tasarlanmıştır. Eliptik filtreler için merkez frekansları 400, 800, 1200, 1600 ve 3200 Hz olarak seçilmiştir.

4. SINIFLANDIRMA ALGORITMASI

Yapay Sinir Ağı (YSA) yapıları sınıflandırma problemlerinin çözümünde oldukça sık olarak kullanılan bir sınıflandırıcıdır. Bu problemlerde, sınıflara ait ayırt edici özelliklerden elde edilen veriler ağırlık girişini, sınıfları belirleyen ikili düzendeki sayılar da ağırlık çıkışı oluşturmaktadır [25,26]. Bu çalışmada Çok katmanlı algılayıcı (MLP tipi) YSA yapısı kullanılmıştır.

MLP ağı bir giriş katmanı, bir veya daha fazla saklı katman ve bir çıkış katmanından oluşur. Her katman bünyesinde bir çok nöron hücresi bulundurulur. Bu hücreler birbirlerine ağırlıklı bağlantılarla bağlıdır. MLP ağı n giriş vektörünü, üzerinde doğrusal olmayan işlemler yaparak l çıkış vektörüne dönüştürür. Ağırlık çıkışı aşağıda tanımlanan etkinlik (aktivasyon) fonksiyonuna sahip çıkış katmanı tarafından belirlenir.

$$x_o = f\left(\sum_h x_h w_{ho}\right) \quad (7)$$

Burada $f()$ etkinlik fonksiyonu, x_h h. saklı katman nöronunun aktivasyonu, ve w_{ho} h. saklı katman nöronu ile o. çıkış katmanı arasındaki bağlantının ağırlığıdır. En çok kullanılan etkinlik fonksiyonu Denklem 8’de verilen Sigmoid fonksiyonudur.

$$x_o = \frac{1}{1 + \exp\left(-\sum_h x_h w_{ho}\right)} \quad (8)$$

Saklı katmanın aktivasyon seviyesi de çıkış katmanın aktivasyonu gibi bulunur. Hesaplanan çıkış değeri ile hedef değer arasındaki farka dayanan bir hata değeri aşağıdaki gibi tanımlanabilir.

$$E = \frac{1}{2} \sum_s \sum_o \left(t_o^{(s)} - x_o^{(s)}\right)^2 \quad (9)$$

Burada N veri kümesindeki örnek sayısı L ise çıkış nöronu sayısını göstermektedir. MLP ağı eğitiminin amacı katmanlar arasındaki bağlantıların ağırlıklarını değiştirerek hata (E)’yi en aza indirmektir. Ağırlıklar Eğim Düşümü (Gradient Descent) ve Geri Yayılım (Backpropagation) algoritmaları ile ayarlanmaktadır. Bu algoritmalar birbiriyle ilişkilendirilmiş giriş ve hedef, t_o , verilerini eğitim kümesi olarak kullanmaktadır. MLP yapısının eğitimi sırasında,

eğitime rasgele seçilmiş bir başlangıç ağırlık kümesi ile başlanır ve eğitim w_{ih} ve w_{ho} optimize edilene kadar devam ettirilir.

Hatayı geriye yayma algoritmasına göre; her nöron arasındaki bağlantının ağırlığı aşağıda belirtildiği gibi değiştirilerek hata (E) küçültülmeye çalışılır. Bu işlem ağırlıkların en uygun değeri bulunana kadar devam ettirilir.

$$\Delta w_{ho} = -\eta \frac{\partial E}{\partial w_{ho}} = -\eta \delta_o x_h \quad (10)$$

$$\Delta w_{ih} = -\eta \frac{\partial E}{\partial w_{ih}} = -\eta \delta_h x_i \quad (11)$$

Bu denklemlerdeki E, Denklem 9’te tanımlanan hata fonksiyonudur. $\delta_o = x'_o(t_o - x_o)$ ve

$\delta_h = x'_h \sum_o \delta_o w_{ho}$ dir. Eğer aktivasyon fonksiyonu

sigmoid fonksiyon ise $x'_o = x_o(1 - x_o)$ ve $x'_h = x_h(1 - x_h)$ olacaktır.

Bu uygulama Matlab 6.5 ortamında Neural Network Toolbox kullanılarak gerçekleştirilmiştir. Bölüm 3’de elde edilen 38 öznitelik vektörü [-1 1] aralığında ölçeklendirilerek yapay sinir ağı için giriş olarak kullanılmıştır.

Denemeler için 38 girişli, farklı saklı katman nöron sayısına ve 4 çıkış nöron sayısına sahip yapay sinir ağı yapıları oluşturulmuştur. Çıkış katmanında dörtlü kodlama yapılmıştır. Kodlama da kızgınlık için [0,0,0,1], mutluluk için [0,0,1,0], üzüntü için [0,1,0,0] ve normal için [1,0,0,0] kullanılmıştır. Yapay sinir ağının çıkışında “baskın olan seçilir” (winner-take-all) algoritması ile duygusal durum ayrımı gerçekleştirilmiştir. Yapılan farklı denemeler içerisinde en iyi başarımlar 9 saklı katman nörona sahip YSA için elde edilmiştir. Tablo-1 elde edilen bu sonuçtan hareketle hesaplanmış olan doğruluk (confusion matrix) tablosunu göstermektedir.

Tablo 1. 9 saklı katman nöron sayısına sahip YSA için eğitim ve test başarımları

Test					Eğitim				
	N	Ü	M	K		N	Ü	M	K
N	35	4	0	1	N	39	0	0	0
Ü	3	28	0	0	Ü	0	31	0	0
M	1	0	20	14	M	0	0	36	0
K	0	0	8	55	K	0	0	1	62
Genel Başarım(%)					Genel Başarım (%)				
81.65					94.4				

N: Normal, Ü: Üzüntü, M: Mutluluk, K: Kızgın

Test verileri için % 81.65 başarımlar elde edilmiştir. Eğitim setinde ise başarımlar %94.4 olarak tespit edilmiştir. Test setinde %90 başarımlar oranı ile en iyi tespit edilen duygu üzüntü duygusu iken kızgınlık ve normal ruh halleri ise %87’lik doğruluk göstermektedir. Mutluluk duygusu ise %58’lik

başarım oranı ile en kötü tespit edilen duygu sınıfı olarak karşımıza çıkmaktadır.

5- TARTIŞMA VE SONUÇ

Yapılan denemelerde eğitim için ayrılan örnekler test için kesinlikle kullanılmamıştır. Testler sonucunda incelenen ruh halleri içinde en iyi tespit edilen duygu normal duygusu iken en kötü tespit edilen duygu ise mutluluk duygu sınıfı olmuştur. Tablodan da görüldüğü gibi yanlış tespit edilen 15 mutluluk duygusunun 14 tanesi kızgınlık duygusu olarak sınıflandırılmıştır. Aynı şekilde yanlış sınıflandırılan 8 adet kızgınlık ruh halinin hepsi mutluluk olarak sınıflandırılmıştır. Bu sonuçlardan hareketle elimizdeki öznelilikler ile kızgınlık ve mutluluk ruh hallerinin birbirinden ayrılmasının zor olduğunu söylenebilir. Bu problemi ortadan kaldırmak için sınıflandırma işleminde, ayrıştırılması zor olan ruh hallerinin gruplandırılarak, sınıflandırma probleminin çözümü önerilebilir. Mutluluk-kızgınlık bir grubu, üzüntü-normal ise diğer grubu oluşturacak şekilde bir düzenleme yapılabilir. Bu iki grubun birbirinden ayırımının gerçekleştirilmesinden daha sonra grupların kendi içinde bir ayrıma tabi tutulması ile başarımın artacağı düşünülmektedir.

Tablo-2’de test verileri üzerinde, farklı saklı katman nöron sayısına sahip YSA eğitimleri sonucunda, her bir duygu sınıfı için doğru olarak sınıflandırılan toplam değerler gösterilmektedir. En yüksek genel başarım %81.65 ile 9 saklı katman nöron sayısına sahip YSA için elde edilmiştir. Farklı sayıdaki saklı katmana karşılık en yüksek sayıda doğru olarak tespit edilen duygular Tabloda işaretlenmiştir.

Tablo 2. Farklı saklı katman nöron sayılarına sahip YSA’da her bir duygu sınıfı için doğru olarak sınıflandırılan duygu sayısı

Nöron Sayısı	Kızgın (63)	Mutlu (35)	Üzgün (31)	Normal (40)	Başarım (%)
9	55	20	28	35	81.65
10	48	20	28	34	76.92
12	52	16	23	36	75.15
13	55	20	26	34	79.88
16	48	19	27	34	75.74
19	46	20	26	37	76.33
20	47	24	25	34	76.92

Açık olarak görüldüğü gibi her bir duygu sınıfı için farklı ağ topolojileri en yüksek tanıma oranları üretmektedir. Bu sonuç her bir duygu sınıfının tespiti için modüler yapıda farklı ağ topolojileri kullanılmasının başarımı artırabileceğini işaret etmektedir. İlerleyen çalışmalarda bu çalışmanın sonucunda elde edilmiş olan bulgular doğrultusunda duygu sınıflandırması için modüler yapıların kullanılması öngörülmektedir.

TEŞEKKÜR

Bu çalışma TUBİTAK tarafından desteklenen 104E179 nolu ve “İnsan-Bilgisayar Etkileşimini Geliştirmek için Ses ve Yüz Görüntü İşaretlerinden Çok Kipli Biometrik Özneliliklerin Belirlenmesi ve Etkin Birleştirilmesi” isimli proje çerçevesinde gerçekleştirilmiştir.

KAYNAKLAR

- [1] Pantic M, Sebe N, Cohn JF and Huang T, “Affective Multimodal Human-Computer Interaction”, in Proc of ACM Int. Conf on Multimedia, 669-676, 2005
- [2] Wang Yand Guan L, “An investigation of speech based human emotion recognition”, in IEEE 6th Workshop on Multimedia Signal Processing, 15-18, 2004
- [3] Ververidis D and Kotropoulos Y, “Automatic speech classification to five emotional states based on gender information”, in Proc. 12th European Signal Processing Conf. . 341-344, 2004
- [4] Ververidis D and Kotropoulos D, “Emotional speech classification using Gaussian mixture models and the sequential floating forward selection algorithm”, 2005
- [5] Fragopanagos N and Taylor JG, “Emotion recognition in human-computer interaction”, Neural Networks, 18, 389-405, 2005
- [6] Reynolds, C, Ishikawa, M and Tsujino, H, “Realizing affect in speech classification in real-time.” Aurally Informed Performance: Integrating Machine Listening and Auditory Presentation, in Robotic Systems, In conjunction with AAAI Fall Symposia, 2006
- [7] Mehrabian A, “Communication without words,” Psychol. Today, vol. 2, no. 4, pp. 53-56, 1968.
- [8] Moziconacci, “Pitch variations and emotions in speech”, in ICPhS 95, p.178, 1995
- [9] Schere K.R., “How emotion is expressed in speech and singing” in ICPhS, 1995
- [10] Klasleier G, Sendmerier W .F., “Objective voice parameters to characterize the emotional content in speech” in ICPhS, 1995
- [11] Russell J. A., “Is there universal recognition of emotion from facialexpression?,” Psychol. Bull., vol. 115, no. 1, pp. 102-141, 1994.
- [12] Pao T.L, Chen Yu-Te, Jun-Heng Yeh and Wen-Yuan Liao, “Detecting Emotions in Mandarin Speech” Computational Linguistics and Chinese Language Processing, 10,347-362, 2005
- [13] Razak, A.A.; Komiya, R.; Izani, M.; Abidin, Z., “Comparison between fuzzy and NN method for speech emotion recognition”, ICITA 2005. Third International Conference on ,1, 297 - 302 , 2005.
- [15] Bahtti M. W., ling Guan, “A Neural Network Approach for Human Emotion Recognition in Speech”, IEEE , 2, 181-184, 2004

- [16] Kwon Oh-W., Chan K., Hoa J., Lee Te-W. "Emotion Recognition by Speech Signal", EUROSPEECH, 125-128, 2003.
- [17] Rank E. and Pirker H., "Generating emotional speech with a concatenative synthesizer", in Proceedings, ICSLP '98, 3, 671-674, 1998
- [18] Cahn J., "Generating expression in synthesized speech", Master's thesis, Massachusetts Institute of Technology, 1989
- [19] Abelin, Å., Allwood, J., "Cross linguistic interpretation of emotional prosody" ISCA workshop on Speech and Emotion". Newcastle, Northern Ireland, 110-113, 2000
- [20] Mesut Meral, Hazım K. Ekenel, A. Sumru Özsoy "Türkçe'de Duygu Çözümlemesi" Boğaziçi Üniversitesi, In Proceedings of 17th National Conference on Turkish Linguistics.
- [21] Drioli C., Tisato G., Cosi P. and Tesser F., "Emotions and Voice Quality: Experiments with Sinusoidal Modeling", VOQUAL'03, 127-132, 2003.
- [22] Murray I. and Arnott J.L., "Towards theSimulation of Emotion in Synthetic Speech: AReview of the Literature on Human Vocal Emotion," Journal of the Acoustic Society of America, 93, 1097-1108, 1993
- [23] Oudeyer, P.Y "The Production and Recognition of Emotions in Speech: Features and Algorithms", International Journal of Human Computer Interaction, 157-183, 2002
- [24] Burkhardt F., Sendlmeier W., "Verification of Acoustical Correlates of Emotional speech Using Formant-synthesis", in Proceedings of the ISCA Workshop Speech and Emotion, 2000.
- [25] Rafiq, G. Bugmann D. J. Easterbrook., Neural Network Design for Engineering Applications, Computer And Structures, (79), 1541-1552, 2002.
- [26] Loh, L. Tim, "A Comparison of Prediction Accuracy, Complexity, and Training Time of Thirty Three old and New Classification Algorithm", Machine Learning 40(3), 203-238, 2000