

T.C.

GEBZE YÜKSEK TEKNOLOJİ ENSTİTÜSÜ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

BULANIK K-EN YAKIN KOMŞULUK
TABANLI İLİŞKİ MATRİSİ İLE EMG
İŞARETLERİNİN SINIFLANMASI

Alpaslan GÖZEL

YÜKSEK LİSANS TEZİ

ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

T.C. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ

TEZ DANIŞMANI

Yrd.Doç.Dr. A. Arif ERGİN

109942

GEBZE

2001

Alpaslan Saeel 'ın tez çalışması, G.Y.T.E. Mühendislik ve Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 20.08.2001 tarih ve 2001/122 sayılı kararıyla oluşturulan jüri tarafından Elektronik Müh., Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.



JÜRİ

ÜYE
(Tez Danışmanı)

: Yrd. Doç. Dr. A. Arif Ergin,

ÜYE

: Yrd. Doç. Dr. Oguz Kucur.


ÜYE

: Yrd. Doç. Dr. Eren Uçkan

ONAY

G.Y.T.E. Mühendislik ve Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 27.09.2001 tarih ve 2001/126 sayılı kararı.





ÖZET

Bu tezde elektromiyogram (EMG) işaretlerini sınıflayan bir Bulanık K-En Yakın Komşuluk (BK-EYK) tabanlı Bulanık İlişki Matrisi (BİM) sınıflayıcısı önerilmiştir. Bu algoritma klasik BK-EYK sınıflayıcısı ve Keskin K-En Yakın Komşuluk (K-EYK) sınıflayıcısı ile karşılaştırılmıştır.

Önerilen algoritma temel olarak BK-EYK ve bulanık mantık operatör tabanlıdır. Klasik BK-EYK’da bütün öznitelikler kullanılırken BK-EYK tabanlı BİM sınıflayıcısında her öznitelik ayrı ayrı işleme sokulur. Neticede her öznenin tüm sınıflara üyelik değerleri elde edilir. Bu değerler BİM adı verilen bir matriste toplanır. Bu matrise bulanık mantık operatörü olan MAX işlemi önce satır sonra da sütun bazında uygulanarak istenilen sınıflama gerçekleştirilir.


Önerilen sınıflayıcı, bicepslerden elde edilen EMG işaretinin sınıflamasında kullanılmıştır. İşaretler dirsek kapama, dirsek açma, bilek döndürme ve bükme, kavrama ve dinlenme olmak üzere altı farklı hareket içindir. Kol hareketlerinin EMG işaretleri 26 yaşındaki bir erkek denekten her hareket için 12 defa alınmıştır. Sinyaller Auto Regressive (AR) analiz metodu ile model derecesi dört seçilerek elde edilmiştir. Diğer bir deyişle 4 öznitelikli 72 örnek veri 6 kol hareketi için oluşturulmuştur. “Leave-one-out” yöntemi kullanılarak bu dataya değişik sınıflayıcılar uygulanmıştır. Elde edilen sonuçlar bu tezde önerilen BK-EYK tabanlı BİM sınıflayıcısının, diğer denenen yöntemlerden daha yüksek bir sınıflama performansına sahip olduğunu gösterir. Bu algoritma, iyi sınıflama performansının yanında, bir işaretin sınıflanması için kaç öznenin ideal olduğunu da uygulama sırasında göstermiştir.

SUMMARY

A fuzzy k-nearest neighbour-based fuzzy relation matrix algorithm is proposed as a pattern classifier for classification of electromyographic (EMG) patterns, and compared with fuzzy k-nearest neighbour (FK-NN) and crisp K-Nearest Neighbour algorithms (K-NN)

The proposed algorithm is basically based on the FK-NN and fuzzy logic operators. However, unlike FK-NN that uses combination of all features, it processes each feature for each class, and constructs a relation matrix consisting of a membership degree of each feature for each class. The fuzzy logic operator "maximum" (MAX) is applied to the relation matrix's rows and columns, and finally, a membership degree of a pattern is computed to show how much the pattern belongs to each class.

This algorithm is used in the classification of EMG patterns, which are obtained from EMG signals measured from biceps. The signals are recorded during six different arm movements, which are elbow flexion and extension, wrist supination and flexion and grasp and resting. Each arm movement was performed twelve times by a 26 year-old male subject, and their signals were recorded. The signals were modelled using Auto Regressive (AR) analysis method with "model order four" that is a number of features used as inputs to the pattern classifiers. In other words, four features and 72 samples (vectors), 12 of which belongs to each arm movement (e.g. each class) were obtained. The results of a "leave-one-out" test show that the proposed fuzzy k-nearest neighbour-based fuzzy relation matrix algorithm yields higher recognition rates than the other tried methods. It also gives an idea of how much a pattern belongs to each class.




TEŞEKKÜR

Bu tez çalışmasında bana yardımcı olan hocam Yrd. Doç. Dr. **A. Arif ERGİN**'e, bir süre danışmanlığımı yapan hocam Yrd. Doç. Dr. **Ertuğrul KARAÇUHA**'ya ve arkadaşım Araş. Gör. **Hüseyin ŞEKER**'e teşekkürü bir borç bilirim.

Alpaslan GÖZEL

Ağustos 2001, GEBZE



İÇİNDEKİLER DİZİNİ

ÖZET	iv
SUMMARY	v
TEŞEKKÜR	vi
İÇİNDEKİLER DİZİNİ	vii
SİMGELER VE KISALTMALAR DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
TABLolar DİZİNİ	xi
1. GİRİŞ	1
1.1 EMG İşaretlerinin İşleniş Amacı	2
1.2 Temel Bulanık Mantık Teorisi	2
1.3 Tez Çalışmasının Kapsamı	3
2. EMG İŞARETLERİNİN İŞLENMESİ VE AR (ÖZ BAĞLANIMLI- AUTO REGRESSIVE) MODEL KATSAYILARININ ELDE EDİLMESİ	4
2.1 İşaret İşlemeye Giriş ve Temel Kavramlar	4
2.2 Doğrusal (Linear) Zaman Serilerinin Modellenmesi	6
2.3 AR Katsayılarının Kestirimi	8
2.3.1 Özilişki Yöntemi	8
2.3.2 PARKOR Yöntemi	10
2.4 Sinir Akımı	13
2.4.1 Dinlenme Halinde Nevron	13
2.4.2. Sinirde Eylem Akımı	14
2.4.3 Sinirde Uyarının Yayılması	15
2.4.4 Sinir Akımının Ölçülmesi	16
2.4.5 Uyarıda Hep Ya da Hiç İlkesi	17
2.5 Kol Hareketlerine Ait EMG İşaretleri İçin AR Katsayılarının Bulunmasında Kullanılan Deney Ölçüm Düzenegi ve AR Katsayılarının Tespiti	17
2.5.1 Deney Ölçüm Düzenegi	18
3. BULANIK KÜMELER TEORİSİ	20




3.1 Bulanık Kümeler Teorisi	20
3.2 Bulanık Sayılar Arasında En Büyük (MAX) En Küçük (MİN) İşlemleri	22
3.3 Bulanık İlişki Matrisi	23
3.4 Üyelikler Arasındaki Uzaklık	25
3.5 Üyelik Değerlerinin Elde Edilmesi	26
4. BULANIK SINIFLAYICILAR VE İLİŞKİ MATRİSİ	27
4.1 Örnek Veri Seti	27
4.2. Mevcut K-EYK Sınıflayıcıları	28
4.2.1 Keskin K-EYK Sınıflayıcısı	28
4.2.2. Bulanık K-EYK Sınıflayıcısı	30
4.3 BK-EYK Tabanlı BİM Sınıflayıcısı	33
5. SINIFLAMA SONUÇLARI	38
5.1 Keskin K-EYK ve BK-EYK Sınıflayıcısı	38
5.2 BK-EYK tabanlı BİM Sınıflayıcısı	40
5.3 Bulanık En Yakın Üyelik Sınıflayıcısı	42
5.3 Yapay Sinir Ağları (Back Propagation Neural Network) Sınıflayıcısı	44
6. SONUÇLAR	45
KAYNAKLAR	47
ÖZGEÇMİŞ	49
İÇİNDEKİLER	51
EK-1	
EK-2	



SİMGELER VE KISALTMALAR DİZİNİ


AR	: Auto Regressive
EMG	: Elektromiyogram
MR	: Manyetik Rezonans
K-EYK	: K- En Yakın Komşuluk
BK-EYK	: Bulanık K- En Yakın Komşuluk
BİM	: Bulanık İlişki Matrisi
BEYÜ	: Bulanık En Yakın Üyelik
ARMA	: Auto Regressive Moving Average
MA	: Moving Average
MDP	: Miyoelektrik Denetimli Protez
ANN	: Artificial Neural Network

ŞEKİLLER DİZİNİ



Şekil	Sayfa
2.1 İşaretlerin Sınıflandırılması	4
2.2 (A) ARMA Modeli Gösterimi	7
2.2 (B) MA Modeli Gösterimi	7
2.2 (C) AR Modellerinin Gösterilimi	7
2.3 PARKOR Yönteminin Akış Diyagramı	12
2.4.1 Negatif Elektrik Durumu	13
2.4.2 Uyarılma İle Ters Kutuplanmış Bir Kas Hücresi	14
2.4.3 Ters Kutuplanmış Bir Kasda Hareketin İlerlemesi	14
2.4.4 Sinir Akımının Neuron Boyunca İlerlemesi	14
2.5.1 MDP'lerin Çalışma Şekli	17
2.5.2 İşaret İşleme Birimi Blok Diyagramı	18
2.5.3 Hareket Bilgisinin Elde Edilmesindeki Adımlar.	18
3.1 (A) X ve Y Gibi İki Bulanık İlişkisinin Temsili	24
3.1 (B) Bulanık İlişki Matrisi	24
4.1 Örnek Veri Setinin Grafiği	28
4.2 Her Bir Öznitelik İçin Euclid Uzaklıkları ve Sıralanması	31
4.3 BK-EYK Tabanlı BİM Sınıflayıcısının Blok Diyagramı	35

TABLÖLAR DİZİNİ



Tablo

Sayfa

3.1 Yaşlılıkla İlgili Üyelik Değer Tablosu	21
3.2 Bulanık Mantık İle Klasik 1/0 Mantığındaki Bazı İşlemlerin Karşılaştırmalı Tablosu	22
4.1 Örnek Veri Seti	27
4.2 (A) Keskin K-EYK Sınıflayıcısı İçin Euclid Uzaklığı Hesabı Ve Sıralanması	29
4.2 (B) Komşuluk İle Değişen Sınıflama Sonuçları	29
4.3 Her Bir Öznitelik İçin Euclid Uzaklıkları Ve Sıralaması	36
5.1 BK-EYK ve Keskin K-EYK Sınıflayıcısının Performansı	39
5.2 BK-EYK ve Keskin K-EYK Sınıflayıcısının Performansı	39
5.3 BK-EYK-BİM ve Keskin K-EYK BİM Sınıflayıcısının Performansı	40
5.4 BK-EYK-BİM ve Keskin K-EYK BİM Sınıflayıcısının Performansı	41
5.5 BİM kullanılarak ve kullanmadan sınıflamaların karşılaştırılması	41
5.6 FEYÜ Sınıflayıcısı İçin Elde Edilen Sınıflama Sonuçları	43
5.7 FEYÜ Sınıflayıcısı İçin Elde Edilen Doğru Sınıflama Sonuçları	43
5.8 ANN İle 2 Öznitelik ve 4 Öznitelik Kullanılarak Yapılan Sınıflama Sonuçları	44
6.1 Algoritmalara Ait Doğru Sınıflama Sonuçları (%) De Olarak Verilmiştir	45
6.2 Algoritmalara ait doğru sınıflama sonuçları (%) de olarak verilmiştir	45

1. GİRİŞ

Vücut çeşitli fonksiyonlarını yaparken kendi monitör işaretlerini de üretir. Bu işaretler çoğu kez karmaşık biyolojik yapıdan dışarıya kolay anlaşılabilir bilgileri taşımazlar. Vücut içindeki olayların anlaşılabilmesi için bunların işlenmesi ve yorumlanması gerekir [5].

Biyoelektrik potansiyeller ve sinirsel iletim, beyin, kalp ve çeşitli kas hareketleri ile ilgilidirler. Bir kısım hücrelerdeki elektrokimyasal olayların sonucu iyonik akımlar oluşur. Bu akımlar elektrot yardımıyla algılanır, işaret işleme işlemlerinden sonra çeşitli hastalıklara teşhis konulmasında yararlanır [3].

Vücutta elektriğin iletilmesi fikri ilk olarak 1786 İtalyan anatomi profesörü Luigi Galvani tarafından ortaya atılmıştır. Galvani yaptığı çalışmada bir kurbağa bacağındaki elektriksel aktiviteyi incelemeye çalışmıştır. Sonraki yüzyılda bu konuda birçok çalışma yapılmıştır. Fakat 1903 yılında Hollandalı fizikçi William Einthoven telli galvometreyi bulmasına kadar bu elektriksel aktivitenin pratik bir uygulaması yapılamamıştır. Elektronikteki gelişmeler ve fizyolojik alandaki çalışmalar, biyolojik işaretlerin işlenmesi ve değerlendirilmesi alanında yeni ufuklar açmıştır [7].

Elektromiyogram (EMG); kasın kasılması sonucu ortaya çıkan biyopotansiyel işaretlerdir. Bunların kaynağı vücutta meydana gelen çeşitli elektrokimyasal olaylardır. Kas aksaklıklarını tespit edebilmek için kasların ürettiği elektriksel işaretlerin analiz edilmesine ihtiyaç vardır. Vücutta farklı fonksiyonlarda çok sayıda ve değişik nitelikte kas bulunduğundan EMG işaretlerinin işlenmesi zordur.

Biyolojik işaretlerin teşhis yaparken kullanılması için sınıflandırılması gerekmektedir. Sınıflanmış işaretler daha sonra bilinmeyen işaretlerin tanınmasında kullanılır. Karar verirken sınıflama algoritmalarından yararlanır. Klasik keskin mantık ile işleyen algoritmalar hastalığı ya teşhis eder ya da etmez. Bulanık kümeler teorisi bu durumdan farklı olarak o hastalığa yakınlığı üyelik değeri ile ifade eder. Üyelik değeri “0” ile “1” arasında sonsuz değer alabilir.



1.1 EMG İşaretlerinin İşleniş Amacı

EMG işaretlerinin işlenmesi ve sınıflanması iki yönden önemlidir. Bunlardan ilki çeşitli hastalıkların teşhisi ikincisi de protezlerin geliştirilmesidir. Örneğin kaslarda oluşabilecek bir iletim gecikmesi felçliğe sebep olabilmektedir [8]. Bu yüzden çoğunlukla klinik uygulamalarda kullanılan EMG işaretleri ritim bozukluklarının önceden tesbiti üzerinde durulur.

Protez uygulamalarında ise vücuttaki kaslar, iskelet ve merkezi sinir sistemi model alınarak buralardan alınacak işaretlerin işlenmesi, yorumlanması ve sınıflandırılması yapay protez yapımında kullanılmaktadır.

1.2 Temel Bulanık Mantık Teorisi

Bulanık kümeler (*Fuzzy Sets*) teorisinde bir ifadenin veya değerin herhangi bir kümeye aitliği bir değer ile ifade edilir ve bu değere Üyelik Değeri denir. Üyelik değerlerinin elde edilmesi bulanık mantığın en hassas işlemidir.

Türkçe'de karşılığı Bulanık Mantık olarak bilinen bu teoriyi daha iyi açıklayabilmek için bir örnek verelim. Beyin üzerine çekilen Magnetic Rezonance (MR) görüntülerinin hangisinin hastalıklı bölgeyi, hangisinin beyin sıvısını ve hangisinin beyin hücrelerine ait olduğunu anlamak zordur. Bu yüzden her bir noktanın gri seviye (gray-level) tonu analiz edildiğinde hangisinin hangi sınıfa ait olduğu kesin olarak bilinemez. Klasik mantıkta üyelik olarak iki değer vardır. Belli bir noktaya kadar 1, sonrasında ise 0. Klasik sistemlerde kesin olarak şu bölge sıvıdır veya hastalıklı bölgedir diyerek yanılma ihtimali olan bir varsayım yapmış oluruz. Ancak, bulanık mantık için bu böyle değildir. Verilen bir bölge, daha önceki sınıflamalar veya aitlikler doğrultusunda, “0,8 kemik, 0,15 sıvı ve 0,05 beyin” gibi üyelik değerleri alır.

Bulanık üyelik değeri tesbiti ile verilen sınıflara yakın üyelik değeri tanımlanarak bir sonuca gidilir. Bulanık kümeler teorisinin getirmiş olduğu bu çok değerli mantıktan hareketle bu teori şu ana kadar özellikle tıpta teşhis koymada, örüntü tanıma ve sınıflamada, kontrol sistemlerinde, endüstri mühendisliğinde verimliliği arttırmada ve bunun gibi bir çok alanda kullanılmaktadır.



1.3 Tez Çalışmasının Kapsamı

Bu tez çalışmasında Elektromiyografik (EMG) İşaretlerinin sınıflanmasında kullanılan yöntemler tanıtılmış ve yeni bir yöntem de önerilmiştir. Tezde kullanılan K-En Yakın Komşuluk (K-EYK) sınıflayıcısı [9] en etkin sınıflama algoritmalarından birisidir. Herhangi bir ön kabule gerek duymayan ve ön işlemlere gerek kalmadan, etiketlenmemiş bir örüntüyü sınıflamak için kullanılabilir. Sınıflama performansı, seçilen komşuluk sayısı ile değişebilmektedir. Bu sınıflayıcıda, sınıflanacak olan örüntüye uzaklık olarak en yakın K örüntü alınır ve bu K tane örüntünün üye oldukları sınıflara bakılır. Etiketlenmemiş örüntü eldeki K tane örüntü arasında en fazla üyesi olan sınıfa atanır. Bulanık K-EYK (BK-EYK) sınıflayıcısında ise en yakın K örüntünün üyelik değerine bakılır ve hangisinin üyelik değeri yüksek ise örüntü onun sınıfına atanır. Bu algoritmalarda K en yakın örüntü bulunurken bütün öznitelik değerlerin bir kombinasyonu olan Euclid uzaklığı kullanılır. Fakat, her öznitelik farklı düzeyde örüntünün tanınmasını kolaylaştırabilir veya zorlaştırabilir. Bu tezde bu eksikliği gideren yeni bir sınıflayıcı önerilmiştir. Bu sınıflayıcıda BK-EYK sınıflama algoritması her bir öznitelik için ayrı ayrı işlenmiştir. Her bir sınıf ve her bir öznitelik için elde edilen üyelik değerleri bir matris olarak ele alınır ve bu matrise Bulanık İlişki Matrisi (BİM) adı verilir. Bu matrisi kullanarak sınıflamayı gerçekleştiren algoritmaya da BK-EYK tabanlı BİM sınıflayıcısı denir. Bildiğimiz kadarı ile BİM'ni K-EYK sınıflaması kapsamında kullanması açısından da önerilen algoritma orijinaldir.


Tez konusu olan “elektromiyografik (EMG) işaretlerin BK-EYK tabanlı BİM sınıflayıcısı yardımıyla değerlendirilmesi,” Ankara Bilkent Üniversitesi’nde yapılan IEEE 1999 Sinyal İşleme ve Uygulamaları Kurultayı’nda kitapçığının 99-103 sayfalarında yayınlanmıştır[23].



2. EMG İŞARETLERİNİN İŞLENMESİ VE AR (ÖZ BAĞLANIMLI - AUTO REGRESSIVE) MODEL KATSAYILARININ ELDE EDİLMESİ

2.1 İşaret İşlemeye Giriş ve Temel Kavramlar

Biyolojik ve fiziksel sistemlerden elde edilen işaretlerin çeşitli özellikleri ve karakteristikleri vardır. Uygun işaret işleme yöntemlerinin uygulanabilmesi için işaretlerin genel karakteristiğinin bilinmesi gerekmektedir. Genel olarak işaretleri belirgin (*deterministic*) ve rastgele (*random*) işaretler olarak iki ana grupta toplamak mümkündür. Şekil-2.1'de işaretlerin genel olarak sınıflandırılmasını gösteren bir tablo görülmektedir [11].



Şekil-2.1 İşaretlerin Sınıflandırılması

Belirgin işaretler, zamanın fonksiyonu olarak tamamen modellenebilen işaretlerdir. Bu işaretler zaman ya da frekansın birer fonksiyonu şeklindedir ve sonlu sayıda terim bulundurulur. Rastgele işaretler ise zamanın fonksiyonu olarak tamamen modellenebilen ifade edilemeyen işaretlerdir.

Belirgin işaretler iki alt guruba ayrılır; periyodik olan ve olmayan işaretler. Periyodik işaretler T periyod olmak üzere her t için $X(t)=X(t+T)$ bağıntısını sağlayan

işaretlerdir. Frekans domeninde, periyodik işaretler Fourier serileri ile temsil edilir. Bu domende temel frekans ve harmonik bileşenler mevcuttur. Periyodik olmayan işaretler de hemen hemen periyodik ve süreksiz işaretler olarak ikiye ayrılabilir. Hemen hemen periyodik işaretler birbirinden bağımsız ve periyodları farklı sonsuz sayıda işaretin kombinasyonu sonucu oluşurlar. Bessel fonksiyonları bu duruma örnek teşkil eder. Süreksiz işaretler ise zaman içinde kısa bir süre ortaya çıkan ve periyodik olmayan işaretlerdir.

Rastgele işaretler, belirgin işaretlere göre işlenmesi daha zor olan işaretlerdir. Rastgele işaret, bir rastgele işlemin bir örnek fonksiyonudur. Aynı rastgele işlemin birkaç örnek fonksiyonu bir araya gelerek bir topluluk (*ensemble*) oluşturur. Rastgele işaretler olasılık yoğunluk fonksiyonu (*probability density function*) ile modellenir. Rastgele işaretler durağan (*stationary*) ve durağan olmayan işaretler olarak ikiye ayrılır. Durağan işaretin istatistiksel özellikleri zamanla değişmez. Bu gruba giren rastgele bir işaretin zaman ortalaması topluluk ortalamasına eşitse buna ergodik işaret denir. Durağan olmayan işaretler işlenmesi en zor işaretlerdir. Hatalı olsa da ergodik olarak varsayıp işlenirler. Örneğin EEG (Elektroenselelofogram) işaretini işlerken elimizde tüm topluluk olmayıp sadece bir örnek fonksiyon bulunabilir. Bundan dolayı ergodiklik varsayımı yapılarak gerekli istatistiksel özellikler, bu örnek fonksiyonun zaman içindeki değişiminden elde edilme yoluna gidilir. Durağan olmayan işaretler için işlem yöntemleri pek etkili olmadıklarında bu tür işaretler durağan kabul edilen dilimlere ayrılarak işlenirler. Dilimlerin uzunlukları işaretin yapısına bağlıdır (ses işaretleri için dilim uzunluğu 10 ms, EEG için birkaç saniyedir).

İşaret işleme açısından işaretlerin diğer bir sınıflaması da işaretlerin sürekli (*continuous*) ve ayrık (*discrete*) olarak sınıflandırılmasıdır. Genel olarak sürekli işaretler zaman içinde herhangi bir anda tanımlanabilirler. Bu işaretlere uygulanan işaret işleme yöntemleri Fourier ve Laplace dönüşümleri ve diğer analog yöntemlerdir. Ayrık işaretler ise ancak belli anlarda tanımlıdır. Genellikle bu işaretler sürekli işaretlerin zaman içinde örneklenmiş ve genlik olarak da kuantalanmış şekilleridir. Bununla beraber tabiatı itibarıyla ayrık olan işaretler de vardır. Bu işaretlere, z-dönüşümü ve ayrık Fourier dönüşümü (*Discrete Fourier*

Transformation) gibi ayrık işaret işleme yöntemleri uygulanır. Donanım açısından ayrık işaretler sayısal sistemlerle işlenir. Sayısal işaret (*digital*) işleme teknikleri günümüzde son derece büyük ilerleme kaydetmiştir. Bu nedenle sürekli işaretler, analog/sayısal çeviriciler yardımıyla ayrıştırılarak bilgisayar ortamında sayısal işaret işleme teknikleriyle işlenebilmektedir.

İşaret işlemede en önemli noktaların başında filtreleme gelmektedir. Filtreleme zaman domeninden ziyade frekans domeninde yapılır. Frekans domeninde işaret, genliği ve fazı, frekansına göre değişen olarak tanımlanır. Frekans domeninde filtreleme işlemi, belirgin işaretler için olduğu kadar, rastgele işaretler için de etkilidir. Rastgele işaretleri işlerken Fourier dönüşümü, işaretin örnek fonksiyonu yerine öz ilişki (*autocorrelation*) fonksiyonuna uygulanır. Bu durumda işaretin güç yoğunluk fonksiyonu ile ilgilenilir [11],[12].

2.2 Doğrusal (Linear) Zaman Serilerinin Modellenmesi

Çoğu sistem, geçmişteki çıkışları ile o andaki ve geçmişteki girişlerinin lineer kombinasyonları ile modellenebilmektedir:

$$y_k = -\sum_{i=1}^p a_i y_{k-i} + \sum_{j=0}^q b_j x_{k-j} \quad (2.1)$$

Bu ifadede x_k ve y_k sistemin girdi ve çıktı serilerinin k ayrık zamanındaki değerleridir. Girişe ait herhangi bir bilgiye erişilemiyorsa, (EMG işaretinde olduğu gibi) giriş beyaz gürültü olarak alınabilmektedir. (2.1) ifadesindeki model parametreleri olan a_i , $i=1, \dots, p$, ve b_j , $j=0, \dots, q$, bilindiği takdirde, geçmişteki giriş ve çıkış değerlerinden k anındaki y_k değeri hesaplanabilir. Bu nedenle bu modelleme doğrusal tahmin (*linear prediction*) olarak da adlandırılır.

(2.1) ifadesine z -dönüşümü uygulanarak sistemin transfer fonksiyonu

$$H(z) = \frac{Y(z)}{X(z)} = \frac{\sum_{j=0}^q b_j z^j}{1 + \sum_{i=1}^p a_i z^i} \quad (2.2)$$

olarak bulunur. Burada $Y(z)$ ve $X(z)$ sırasıyla, x_k ve y_k 'nin z -dönüşümleridir. Sıfırları ve kutupları içeren bu genel model, ARMA (*Autoregressive Moving Average*) model olarak tanımlanır (Şekil 2-2(a)).


Sistem yalnızca giriş işaretleri kullanılarak da modellenenebilir. Bu durumda $a_i = 0, i=1, \dots, p$, olur ki bu model tüm sıfır veya MA (*Moving Average*) olarak bilinir (Şekil 2-2(b)). Bunun ifadesi şu şekilde yazılabilir :

$$y_k = \sum_{j=0}^q b_j x_{k-j} \quad (2.3)$$


(2.1) ifadesinde $b_j, j=1, \dots, q$, katsayılarının sıfır olduğu durumda ise sistem, yalnızca çıkışlar kullanılarak modellenir. Tüm kutup veya AR (*AutoRegressive*) model olarak adlandırılan bu modelin fark denklemleriyle gösterilimi

$$y_k = -\sum_{i=1}^p a_i y_{k-i} + b_0 x_k \quad (2.4)$$


şeklindedir (Şekil 2-2(c)).



(a) ARMA Modeli



(b) MA Modeli



(c) AR Modeli

Şekil-2.2 (a) ARMA, (b) MA ve (c) AR Modellerinin Gösterilimi

Durağan zaman serilerinin AR modeli ile modellenebilmesi mümkündür [13]. EMG işareti her ne kadar durağan değilse de, yeterince küçük zaman aralıklarında durağan sayılabilmektedir [14].

ARMA modeli ile durağan zaman serilerinin lineer modeli AR modeline göre daha az sayıda parametreyle elde edilebilir [13]. Fakat, ARMA parametrelerini elde etmek, AR parametrelerinin bulunmasına göre daha karmaşık ve zordur.

MA modeli, durağan olmayan sistemlerin modellenmesinde daha uygun bir yapıya sahiptir. Bununla beraber, yapılan tez çalışmasında EMG işaretlerinin modellenmesinde, EMG işaretlerinin yeterince küçük zaman dilimlerinde durağan sayılabildiği varsayımından hareketle AR modeli kullanılmıştır.

2.3 AR Katsayılarının Kestirimi

Bir sistem veya işaret modelinin parametrelerini elde etmek, diğer bir ifadeyle parametre kestirimi, zaman serileri analizinde önemli bir konudur. Parametre kestirimi için değişik yöntemler vardır. Bu yöntemlerin çoğu “en küçük kareler” (*least squares*) yaklaşımından yola çıkan ve probleme değişik yollardan çözüm getiren algoritmalarlardır. En küçük kareler tekniğinde, kestirim hatasının karesinin beklenen değerini en küçük yapacak şekilde sistem parametreleri belirlenir. Bu bölümde en küçük kareler tekniğine dayanan özilişki ve PARKOR yöntemleri anlatılacaktır.

2.3.1 Özilişki Yöntemi

Daha önce belirtildiği üzere eğer denklem (2.1)’deki x_k girdileri bilinmiyorsa girdiler beyaz gürültü olarak alınabilmektedir. Bu durumda bir sistemin AR modeli

$$y_k = - \sum_{i=1}^p a_i y_{k-i} + e_k, \quad k=1, \dots, N, \quad (2.5)$$

olarak ifade edilir. Burada y_k , işaretin k anındaki değerini; p , modelin derecesini; a_i , AR katsayılarını; N , örnek sayısını; e_k ise beyaz gürültüyü ifade etmektedir.

Verilmiş herhangi $\hat{a}_i$, $i=1,...,p$, AR katsayıları ile geçmişteki çıkış değerlerini kullanarak k anındaki örneği

$$\hat{y}_k = - \sum_{i=1}^p \hat{a}_i y_{k-i} \quad (2.6)$$

olarak kestirebiliriz. Bu kestirimden doğacak hata ise

$$e_k = y_k - \hat{y}_k = y_k + \sum_{i=1}^p \hat{a}_i y_{k-i} \quad (2.7)$$

olacaktır. Aynı zamanda e_k , erişilemeyen girişin kestirimidir.

Hatanın en küçük olabilmesi için

$$\frac{\partial E\{e_k^2\}}{\partial \hat{a}_i} = 0, \quad i=1,...,p \quad (2.8)$$

olmalıdır. (2.7)'yi (2.8) de kullanarak

$$\frac{\partial E \left\{ \left(y_k + \sum_{i=1}^p \hat{a}_i y_{k-i} \right)^2 \right\}}{\partial \hat{a}_i} = 0$$

$$2E \left\{ \left(y_k + \sum_{j=1}^p \hat{a}_j y_{k-j} \right) y_{k-i} \right\} = 0 \quad (2.9)$$


$$E \{ y_k y_{k-i} \} + \sum_{j=1}^p \hat{a}_j E \{ y_{k-j} y_{k-i} \} = 0$$

$$r_i + \sum_{j=1}^p \hat{a}_j r_{j-i} = 0 \quad (2.10)$$

ifadesini elde ederiz. Burada

$$\hat{r}_{i,j} = E \{ y_{k-j} \cdot y_{k-i} \} = r_{j-i} \quad (2.11)$$

olarak tanımlanmıştır. Denklem (2.10)'dan $i=1,...,p$ için p bilinmeyen bulunmasına yarayan p tane lineer denklem elde edilir:



$$\hat{r}_1 + \hat{a}_1 \hat{r}_0 + \hat{a}_2 \hat{r}_1 + \dots + \hat{a}_p \hat{r}_{p-1} = 0 \quad (2.12.1)$$

$$\hat{r}_2 + \hat{a}_1 \hat{r}_1 + \hat{a}_2 \hat{r}_0 + \dots + \hat{a}_p \hat{r}_{p-2} = 0 \quad (2.12.2)$$

.

.

$$\hat{r}_p + \hat{a}_1 \hat{r}_{p-1} + \hat{a}_2 \hat{r}_{p-2} + \dots + \hat{a}_p \hat{r}_0 = 0 \quad (2.12.p)$$

Bu ifadede $\hat{r}_0, \hat{r}_1, \dots, \hat{r}_p$ gibi $(p+1)$ adet özilişki bilindiği takdirde p tane en küçük kareler manasında en iyi AR katsayılarının $(a_j, j=1, \dots, p)$ bulunabileceği gözükmemektedir. Bu eşitlikler "normal" veya "Yule-Walker" eşitlikleri olarak adlandırılmaktadır [17]. Bu eşitlikleri matris formunda da göstermek mümkündür:

$$\begin{bmatrix} \hat{r}_0 & \hat{r}_1 & \dots & \hat{r}_{p-1} \\ \hat{r}_1 & \hat{r}_0 & \dots & \hat{r}_{p-2} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{r}_{p-1} & \hat{r}_{p-2} & \dots & \hat{r}_0 \end{bmatrix} \begin{bmatrix} \hat{a}_1 \\ \hat{a}_2 \\ \vdots \\ \hat{a}_p \end{bmatrix} = \begin{bmatrix} \hat{r}_1 \\ \hat{r}_2 \\ \vdots \\ \hat{r}_p \end{bmatrix} \quad (2.13)$$

Genel ifadeyle (2.13)'teki matris denklemi

$$\mathfrak{R} \cdot \hat{\underline{a}} = -\underline{r} \quad (2.14)$$


olarak yazılabilir. Bu ifadede $\hat{\underline{a}}$, AR katsayısı vektörü; $\underline{r}$, özilişki vektörü; $\mathfrak{R}$ simetrik Toeplitz yapıdaki özilişki matrisidir. $\mathfrak{R}$ matrisinin tersi alınarak

$$\hat{\underline{a}} = -\mathfrak{R}^{-1} \underline{r} \quad (2.15)$$

AR katsayısı vektörü elde edilir [13],[14].

2.3.2 PARKOR Yöntemi

Yukarıda anlatılan algorithmada AR katsayılarını belirlemek için özilişki matrisinin tersini almak gerekmektedir. Bu işlemden kurtulmak için Levinson ve Durbin tarafından bir yöntem geliştirilmiştir. Kısmi Korelasyon ya da PARKOR adı verilen bu yöntem, p bilinmeyenli problemi ardışıl (*iterative*) olarak çözer. Ardışıl



çözümün i 'inci aşamasında elde edilen a_j katsayıları ($a_j^i, j=1, \dots, i-1$) aynı zamanda i 'inci dereceden AR modelinde j 'inci AR katsayısıdır. i 'inci aşamadaki katsayılar bir önceki aşamanın katsayılarına

$$a_j^i = a_j^{i-1} + k_i a_{i-j}^{i-1} ; j=1,2,\dots,(i-1) ; i \neq 1 \quad (2.16)$$

ifadesiyle bağlıdır. Buradaki k_i katsayıları yansıma veya kısmi korelasyon katsayıları adını alır ve şu şekilde hesaplanır:

$$k_i = - \frac{r_i + \sum_{j=1}^{i-1} a_j^{(i-1)} \cdot r_{i-j}}{E_{i-1}} . \quad (2.17)$$

Aynı zamanda k_i katsayıları ile AR katsayıları arasında şu bağıntı vardır:

$$a_i^i = k_i ; i=1,2,\dots,p . \quad (2.18)$$

(2.17)'deki E_{i-1} ifadesi $(i-1)$ 'inci aşamadaki en küçük kareler ortalama hatasıdır. E_i hatası ise bir önceki aşamadaki hataya şu ifadeyle bağlıdır:

$$E_i = (1 - k_i^2) E_{i-1} \quad (2.19)$$

$$E_0 = r_0 \quad (2.20)$$


Bu ifadelerde, a_j^i , i 'inci dereceden modelin j 'inci AR katsayısıdır. (2.16)-(2.19) eşitlikleri $i=1,\dots,p$ için ardışıl olarak çözülür ve sonuçta p 'inci dereceden AR katsayıları,

$$a_i = a_i^p \quad (2.21)$$

olarak bulunur.

Son aşamada (2.19) ifadesinden hesaplanan en küçük kareler ortalama hatası E_p ,

$$E_p = r_0 + \sum_{j=1}^p a_j r_j \quad (2.22)$$




şeklindedir ve özilişkiler de

$$r_i = \frac{1}{N} \sum_{k=1}^{N-i} y_k \cdot y_{k+i}, k=1, \dots, N \quad (2.23)$$

ifadesi yardımıyla hesaplanır [13].

Levinson ve Durbin tarafından geliştirilen PARKOR yöntemi ile Bölüm 2.4 ve 2.5’de anlatılacak EMG işaretlerine ait AR katsayılarının belirlenmesi metodu bu çalışmada kullanılmış olup bu algoritmaya ait akış diyagramı Şekil-2.3’de verilmiştir.



Şekil-2.3 PARKOR Yönteminin Akış Diyagramı



2.4 Sinir Akımı


Eskiden sinir akımlarının sade bir elektrik akımı olduğu zannedilirdi. Ancak araştırmalar, elektriğin, bilinen herhangi bir sinir akımından çok daha hızlı yayıldığını göstermiştir. Örneğin kurbağanın siyatik sinirinin akım iletme hızı, saniyede ortalama 30 m'dir. Buna karşılık, elektrik akımı saniyede 300000 km'lik bir hızla gider.

Eskiden, sinir akımının, neuronun sitoplazmasındaki sinir liflerinin uzun eksenleri boyunca iletildiği zannedilirdi. Bugün ise, bunun elektrik yüklü taneciklerin (iyon) neuron zarından geçişleri sırasında ortaya çıkan elektro-kimyasal bir olay olduğu görüşü hakimdir. Bu bölümde bu görüş doğrultusunda tezin ileriki kısımlarında kullanılacak olan EMG işaretlerinin oluşumu hakkında bilgi verilecektir.

2.4.1 Dinlenme Halinde Neuron

Akım iletmemekte olmayan bir neurona "dinlenme halinde" denir. Dinlenme halindeki neuron, hücre dışında hücre içine oranla on kat daha yoğun olan sodyum iyonlarına karşı daha az geçirgendir. Dinlenme halinde neuron, sodyum iyonlarının hücre içine yayılmasını önlemek için sürekli olarak enerji harcar. Sodyum iyonları pozitif yüklüdür ve hücre içi ile dışında farklı yoğunlukta olmaları, zarın içi ile dışı arasında bir kutuplaşmayı, yani farklı elektrik yüklerinin oluşmasını sağlar.


Dinlenme halinde negatif elektrik yüklü klor iyonları da, hücre dışında hücre içine oranla daha yoğundur. Pozitif elektrik yüklü potasyum iyonları ile organik iyonlar ise hücre içinde, dışına oranla daha yoğundur. Zarın iç ve dışındaki bu farklı iyon yoğunluğunun oluşturduğu dinlenme potansiyeli denilen potansiyelin değeri ortalama olarak 0.07 Volt'tur.




Şekil 2.4.1 Negatif Elektrik Durumu

2.4.2. Sinirde Eylem Akımı

Neuronun bir bölümü özellikle de protoplazma uzantısının ucu uyarıldığında, bu bölümde hücre zarının sodyum iyonuna karşı geçirgenliği artar. Böylece, bu bölümdeki sodyum iyonları hücre zarını geçerek hücre içine girer ve pozitif elektrik yükleri ile hücre içini dışına oranla 0,05 Volt kadar daha pozitif yaparlar. Bu elektrik farkından doğan gerilime eylem potansiyeli adı verilir. Hücrenin bu küçük bölümüne de polarlığı giderilmiş denir. Dinlenme potansiyelinin yanında eylem potansiyelinin bulunması, eylem akımı denen çevrimsel akım oluşturur. Bu akım eylem potansiyeli alanında negatif yüklü dıştaki alandan pozitif yüklü içteki alana doğru akar. Sonra hücre zarının iç bölümü boyunca, elektrik akımının negatif olduğu dinlenme potansiyeli alanına kadar gider. Orada, hücre zarının pozitif yüklü olan dış bölümüne geçer. Son akım, eylem potansiyelinin bulunduğu alandaki hücre zarının dışında bulunan negatif yüklü alana geri döner. Böylece akım hücre zarını iki kez geçerek bir çevrim oluşturur.



Şekil 2.4.2 Uyarılma İle Ters Kutuplanmış Bir Kas Hücresi



Şekil 2.4.3 Ters Kutuplanmış Bir Kasda Hareketin İlerlemesi

2.4.3 Sinirde Uyarının Yayılması

Bu noktada iki şey gerçekleşir. Eylem potansiyeli alanında sodyum iyonları hücre dışına pompalanır hücre zarının dinlenme potansiyeli geri döner. Bu bölge artık yeniden polarlanmıştır. Çevrimsel eylem akımının gittiği yeni alanda da bir eylem potansiyeli doğar. Sonunda, eylem akımı, neuronun uzunluğu boyunca kısa bir uzaklık aşmıştır. Yukarıda anlatılan tüm olayların yeniden tekrarlanması ile, akım tüm sinir boyunca yayılır.

Görüldüğü üzere, eylem akımının neuron boyunca ilerlemesi, kendi kendine yayılan bir olaydır. Bu akım, bulunduğu bölgenin hemen önünde sodyum iyonlarının hücre içine kaçmasını sağlayarak hücre boyunca kendi kendine ilerler. Bu şekilde ilerleyen bir eylem akımına sinir akımı denir. Bir başka deyişle, sinir akımı, elektro-kimyasal tepkimenin neuron boyunca hareketidir.


Sinir akımı, havai fişğin fitili boyunca ilerleyen kıvılcım ile karşılaştırılabilir. Fitilin bir bölümünün yanmasıyla ortaya çıkan sıcaklık, hemen yanındaki bölümü de ateşler ve böylece kıvılcım kendi kendine gider. Neuronun herhangi bir parçasındaki akım da, bir sonraki neuron bölümünde ilerleyebilmesi için gerekli değişiklikleri yaratır. Ama arada bir fark vardır. Söz konusu fitil ancak bir kez yanabilir ve bir daha kullanılamaz. Neuron ise, yeniden eski haline dönerek, ömür boyu akımları iletebilir. Ancak akım iletiminden sonra, neuronun uyarılamayacağı kısa süreli bir cevap vermeyen dönem gelir. Bu dönem, zarın yeniden polarlanması için gerekli olan süredir. Cevap vermeyen dönem 0,001-0,005 saniye arasında değişir. Buna göre bir saniye içinde bir neuron yüzlerce akım iletebilir.

Sodyum iyonunun hücre dışına pompalandığı yeniden polarlanma olayı için enerji gereklidir. Bu olay için kullanılacak enerjiyi, yaşayan hücrelerde solunum sırasında enerji açığa çıkaran kimyasal tepkimelerde oluşan ATP'nin (adenozin trifosfat) sağladığı sanılmaktadır. Solunum için oksijen gereklidir ve neuronlar oksijensiz kalırsa, akım iletme yetenekleri hızla kaybolur.

Bir neuronun herhangi bir bölümü uyarılabilir ve akım bu noktadan başlayarak hücrenin her iki ucuna doğru gider. Bununla birlikte, yaşayan bir organizmada bu hareketin yönü, hemen her zaman bir tek yöndedir: Protoplazma uzantısından hücre gövdesine, sonra da silindir eksene doğru.

2.4.4 Sinir Akımının Ölçülmesi

Sinir akımı neuron boyunca ilerlerken, sinirin dışında gözlenen elektrik potansiyelinde değişiklikler olur. Bu değişiklikler, sinire batırılmış iki elektrotla bağlanmış bir galvanometre ile ölçülmüştür. Küçük bir uyarı verilince, akım **B** elektrotuna varana kadar, galvanometre hiçbir potansiyel farkı göstermez (Şekil 2.4.4.a). Akım **B** elektrotuna varınca, elektrot, **A** elektrotuna oranla geçici olarak negatif olur (Şekil 2.4.4.b). Akım her ikisi arasındayken iki elektrot da aynı potansiyeli gösterir (Şekil 2.4.4.c). Kısa bir süre sonra, akımın **A**'ya varmasıyla **A**, **B**'ye oranla negatifleşir (Şekil 2.4.3.d). Akım geçince, **A** ve **B** elektrotları gene aynı potansiyele dönerler (Şekil 2.4.4.e).



Şekil 2.4.4 Sinir Akımının Neuron Boyunca İlerlemesi




2.4.5 Uyarıda Hep Yada Hiç İlkesi

Tüm sinir akımları hemen her zaman aynıdır. Uyarının şiddeti ile akımın gücü arasında hiç bir ilişki yoktur; belli bir eşik değerini aşan her uyarı, akım başlatabilir. Buna hep ya da hiç ilkesi adı verilir. Uyarının şiddeti ile iletimin hızı arasında da bir ilişki yoktur. Havai fişek fitili ile benzerlik burada da geçerlidir; kıvılcımın sıcaklığı ve hızı, bu fitili yakmada kullanılan ateşin ısısına ve büyüklüğüne bağlı değildir. Hatta fitil, merceklerle toplanan güneş ışınları ile bile yakılmış olabilir. En önemli etmen, yanmasını başlatmaya yeterli ısının sağlanmasıdır. Fitilin yanma hızı fitilin doğasına, sinir akımının yayılma hızı da neuronun doğasına bağlıdır. İlaçlar sinirleri, dolayısıyla akım iletim hızını etkileyebilir.

2.5 Kol Hareketlerine Ait EMG İşaretleri İçin AR Katsayılarının Bulunmasında Kullanılan Deney Ölçüm Düzeneği ve AR Katsayılarının Tespiti

Bu bölümde anlatılacak olan işaretlerin elde edilmesi 1989 yılında Yük. Müh. Özcan Kuyumcu tarafından yapılan yüksek lisans tezinden alınmıştır. Verilen bilgiler ve sonuçlar geniş bir şekilde bu kaynaktan temin edilebilir [1].


Bir miyoelektrik denetimli protezin (MDP) çalışma biçimi Şekil-2.5.1’de blok diyagramı olarak verilmiştir.



Şekil-2.5.1 MDP’lerin Çalışma Şekli

Yüksek merkezleri istenilen harekete karşı düşecek biçimde kastediği kaslarda üretilen EMG işareti, yüzey elektrodlarıyla ölçülerek işaret işleme katında işlenir ve buradan elde edilen bilgiyle protez motorları kumanda edilir. Protezin eylemini gözler yoluyla izleyen karar merkezleri, kaslarda oluşturdukları kasılmaları ayarlayarak protezin durumunda istenilen değişiklikleri yapabilmektedirler.

Bir MDP, temel olarak bir işaret işleme birimi ile bir motor biriminden oluşur. Buna dair blok diyagram Şekil-2.5.2'de verilmiştir.




Şekil-2.5.2 İşaret İşleme Birimi Blok Diyagramı

İşaret işleme birimi, EMG işaretini ölçer. Yükseltme ve süzme gibi ön işlemlerden sonra bilgi taşıyan parametreleri bulur ve istenilen harekete karar verilir.

2.5.1 Deney Ölçüm Düzeneği

Bu tezdeki çalışmanın amacı, kol hareketlerinin kaslardan alınan işaretlerle modellenmesini sağlamak, protez motorlarına kumanda edecek bilginin elde edilmesi veya kas hastalıklarının önceden tesbiti için sınır değerlerin belirlenmesine yardımcı olmaktır. Bu bilginin elde edilmesindeki adımlar Şekil-2.5.3'de verilmiştir. Bu blok diyagramda sınıflandırma ve karar bölümü için Bulanık Kümeler Teorisi tabanlı sınıflayıcılar kullanılmış olup bu yöntemler bölüm 4 ve 5'de anlatılmıştır.



Şekil-2.5.3 Hareket Bilgisinin Elde Edilmesindeki Adımlar.



EMG işaretlerinin alınmasında bir gümüş-gümüş klorür elektrod çifti kullanılmaktadır. Elektrod bağlanacak yüzey asetonlu pamukla silinerek deri üzerindeki iletkenliği önleyecek yağ ve benzeri maddeler uzaklaştırılır. Yüzey temizlendikten sonra elektrod çifti, iletken pasta sürülerek 3 cm aralıklı kalacak şekilde biceps'lerin en çok kasılma yaptıkları bölgeye yerleştirilir. Referans elektrod, hareketsiz duran diğer bileğe bağlanmalıdır.

EMG kuvvetlendiricisi olarak standart bir enstrümantasyon kuvvetlendiricisi kullanılmıştır [1]. Ayrıca bu devreye 50 Hz'lik şebeke frekansını süzmek için bir de çentik filtre[3],[14] eklenmiştir. Kuvvetlendirici çıkışında ikinci dereceden ve üst kesim frekansı 1 kHz olan bir alçak geçiren Butterworth filtresi kullanılmıştır [1]. EMG işaretleri sıfır ortalamalı olduklarından, gerekli gerilim değerleri arasına bir dc seviye kaydırıcı ötelendikten sonra A/D dönüştürücü (12 bitlik) girişine gönderilir[1].

EMG işaretleri 5 kHz'de örneklenmiştir. Nyquist teoremine göre örnekleme frekansı, incelenen işaretin en yüksek frekans bileşenin iki katı veya daha fazla olmalıdır. EMG işaretlerinin en yüksek frekans bileşeni 1000 Hz olduğuna göre yukarıdaki seçim uygundur.

EMG işaretinin elde edildiği sistemin, özbağlanımlı (AR) bir süreç olarak modellendiği daha önce anlatılmıştı. Bu çalışma sırasında EMG işaretleri çok küçük zaman aralıklarında durağan olarak kabul edildiği için işaretler 300 ms'ye kadar durağan sayılabilmektedir. Bir sistemi en iyi şekilde modelleyebilmek için model parametresinin sonsuz olması gerekir. Ancak bu durum pratikte mümkün değildir. Bu amaçla literatürde de belirtilen model derecesi 4 alınmış olup 4 öznitelik seçilmiştir ve sistem modellenmiştir [9],[15],[16].

EMG işaretleri 26 yaşındaki bir erkek denek üzerinden kol hareketlerinin gerçekleştirilmesi esnasında alınmıştır [1]. İşaretler Dirsek Kapama, Dirsek Açma, Bilek Döndürme, Bilek Bükme, Kavrama ve Dinlenme olmak üzere 6 hareket için alınmış, işlenmiş ve sınıflanmıştır.

Her hareket 12 kez tekrarlanıp her denemede yaklaşık bir saniyede 4800 örnek alınarak saklanmıştır. Deneyler yapılırken, hareketin başlangıç ve bitiş noktaları atılarak, hareketin lineer olduğu bölge alınmıştır ve her denemede kaslara aynı kuvvet uygulanmaya çalışılmıştır [1].



3. BULANIK KÜMELER TEORİSİ

Son yılların en popüler konularından biri olmaya başlayan bulanık kümelerin keskin kümelere kıyasla üstün yanları vardır. Bu sebeple elektronik, işaret işleme, işaret sınıflama [1], tıpta teşhis, kontrol ve bunun gibi çeşitli alanlarda kullanılmış ve olumlu sonuçlar alınmıştır.

Bu bölümde bulanık kümeler teorisine ait bazı işlemler ve bunların klasik küme teorisi ile karşılaştırılması verilecektir.

3.1 Bulanık Kümeler Teorisi

Klasik küme kavramında bir işaret, bir karakter ya da bir sayı bir kümeye ya aittir ya da değildir. Yani, ait olması durumunda o ifade o küme için 1 (Lojik-1) değerini, ait olmaması durumunda ise 0 (Lojik-0) değerini alacaktır. Ancak, bulanık kümeler teorisinde ise bir kümenin elemanının o kümeye ait olması bir üyelik değeri ile açıklanır. Bu üyelik değeri 0 ile 1 arasında herhangi bir değer alabilmektedir. Dolayısıyla küme elemanı için kullanılan ayırd edici bir parametredir. Bunu bir örnekle açıklamak için L.A. Zadeh'in kullanmış olduğu [20] bir üyelik fonksiyonunu ele alalım: $A = (x, U_A(x))$, $x \in U$ olmak üzere bir bulanık ilişki için aşağıdaki ifadeyi tanımlayabiliriz:

$$U_A(x) = \begin{cases} 0 & 0 \leq x \leq 40 \\ \left[1 + \left[\frac{x-40}{5} \right]^2 \right]^{-1} & 40 \leq x \leq 120 \end{cases} \quad (3.1)$$

Burada A bir bulanık alt kümedir ve $U_A(x)$ de A kümesindeki bir x elemanına karşılık gelen üyelik değeridir. Bu küme, 0-120 yaşları arasındaki kişilerin yaşlılık durumları ile ilgilidir ve bunun için bir üyelik fonksiyonu $U_A(x)$ oluşturulmuştur. Bu üyelik fonksiyonu, kümedeki her bir yaşa karşılık gelen bir üyelik değeri oluşturur. Bu durum n elemanlı sonlu bir küme için

$$A = \frac{U_A(x_1)}{x_1} + \frac{U_A(x_2)}{x_2} + \dots + \frac{U_A(x_n)}{x_n} = \sum_{i=1}^n \frac{U_A(x_i)}{x_i} \quad (3.2)$$

şeklinde ifade edilir. Bu eşitlik notasyon olarak verilmiştir. Örneğin verilen illerin doğru illeri olduğunu gösteren alt küme

$$A = \frac{0.0}{\text{İstanbul}} + \frac{0.2}{\text{Ankara}} + \frac{0.6}{\text{Sivas}} + \frac{1.0}{\text{Ağrı}}$$

şeklinde gösterilir.

Eğer bulanık küme sonlu değil ise bu durum

$$A = \int_x \frac{U_A(x)}{x} \quad (3.3)$$

şeklinde ifade edilir [2].

Tekrar yukarıdaki örneği gözönüne alalım. Bazı x (yaş) değerleri için üyelik değerleri hesaplanırsa aşağıdaki değerler elde edilir.

YAŞ (x)	Üyelik - U(x)	YAŞ (x)	Üyelik - U(x)
0	0.0000	60	0.9412
40	0.0000	80	0.9846
41	0.0385	100	0.9931
50	0.8000	120	0.9961

Tablo 3.1 Yaşlılıkla İlgili Üyelik Değer Tablosu

Bu değerleri ayrıca yukarıda da belirttiğimiz üzere şu şekilde de yazabiliriz:

$$A(x) = \frac{0}{0} + \frac{0}{40} + \frac{0.0385}{41} + \frac{0.8}{50} + \frac{0.9412}{60} + \frac{0.9846}{80} + \frac{0.9931}{100} + \frac{0.9961}{120}$$

Burada yaşlılığı temsil eden üyelik fonksiyonunu düşündüğümüzde klasik küme kavramında bazen 50, 60, 80 bazen de 100 ve yukarısı yaşlı insan sayılır. Ancak bu kişiden kişiye ülkeden ülkeye değişebilmektedir. Ayrıca bir insan 80 yaşındaysa tam yaşlı demek midir? diye bir soruya klasik küme teorisi ile cevap

verilemez. Bu durumda bulanık kümeler teorisi ise bu sorunun cevabını oluşturulan üyelik fonksiyonunu ve elde edilen üyelik değerlerini kullanarak çok basit bir şekilde verecektir. Üyelik fonksiyonları çok değişik şekillerde oluşturulabilmektedir. En uygun üyelik değeri ve üyelik fonksiyonu konunun uzmanlarına sorularak elde edilir.

3.2 Bulanık Sayılar Arasında En Büyük (MAX) En ve Küçük (MİN) İşlemleri

A ve B iki bulanık alt küme olmak üzere bu iki kümenin oluşturduğu üyelik değerleri ve fonksiyonları arasındaki MAX ve MİN işlemleri A ve B kümelelerinin bir x değeri için alacakları üyelik değerlerinin Büyük (MAX) veya Küçük (MİN) olanının tesbitine yararmaktadır. Bu işlemleri bundan sonra kısaca MAX ve MİN işlemleri olarak kullanacağız.

MİN işlemi

$$U_{A \wedge B}(x) = \text{MIN}(U_A(x), U_B(x)) = U_A(x) \wedge U_B(x) \quad (3.4)$$

şeklinde ifade edilir.

MAX işlemi ise

$$U_{A \vee B}(x) = \text{MAX}(U_A(x), U_B(x)) = U_A(x) \vee U_B(x) \quad (3.5)$$

şeklinde ifade edilir. Klasik küme kavramında MAX işlemi OR işlemine, MİN işlemi ise AND işlemine karşılık gelmektedir. Bu durum Tablo 3.2’de gösterilmiştir.

	Bulanık Kümeler Teorisi	Klasik Küme Teorisi
$\vee$	MAX	OR
$\wedge$	MİN	AND

Tablo-3.2 Bulanık Mantık İle Klasik 1/0 Mantığındaki Bazı İşlemlerin Karşılaştırmalı Tablosu

MAX ve MİN işlemleri tek tek gerçekleştirilebildiği gibi beraber de kullanılabilirler. Bu genellikle BİM elde edildikten sonra karar verme işleminde kullanılmaktadır.

3.3 Bulanık İlişki Matrisi

Bulanık ilişki matrisi oluşturmak için üyelik fonksiyonu ve değerlerinden yararlanılır. Bulanık ilişki matrisi bir sistemi temsil eden sabit bir matris olabileceği gibi, üyelik fonksiyonundaki herhangi bir değere göre değişebilen üyelik değerlerinden oluşmuş bir matris de olabilir. Bu matrise ayrıca üyelik değerlerinden oluştuğu için Üyelik Matrisi de denmektedir.

X 6 elemanlı ve Y de 5 elemanlı iki bulanık küme olsun. Bulanık ilişki matrisine ait ifade

$$R(X,Y) = [x | x \in X, (x,y) \in R \quad \exists y \in Y \text{ için}] \quad (3.6)$$

$$R(X,Y) = [y | y \in Y, (x,y) \in R \quad \exists x \in X \text{ için}] \quad (3.7)$$

şekillerinde yazılabilmektedir [18].


Bu ifadeler arasındaki MAX-MAX, MAX-MİN ve MİN-MAX işlemleri sırasıyla şu şekilde tanımlanır [1],

$$MAMA(R) = \max_{y \in Y} \max_{x \in X} U_R(x,y) \quad (3.8)$$

$$MAMI(R) = \max_{y \in Y} \min_{x \in X} U_R(x,y) \quad (3.9)$$

$$MIMA(R) = \min_{y \in Y} \max_{x \in X} U_R(x,y) \quad (3.10)$$

Buna ait bir örnek vermek için aşağıdaki ilişkiyi ele alabiliriz. Şekil 3.1'de iki adet bulanık küme arasındaki alakayı temsil eden bir bulanık ilişki ve buna ait BİM görülmektedir.



Şekil 3.1 (a) X Ve Y Gibi İki Bulanık İlişkisinin Temsili

	y1	y2	y3	y4	y5
x1	0,9	1	0	0	0
x2	0	0,4	0	0	0
R= x3	0	0	1	0,2	0
x4	0	0	0	0	0,4
x5	0	0	0	0	0,5
x6	0	0	0	0	0,2

Şekil 3.1 (b) Bulanık İlişki Matrisi

R bulanık ilişki matrisinin her bir satırında MAX, daha sonra elde edilen sütunda da MAX işlemi uygulanabilir.

Bu matris karar verme işleminde önemli rol oynamaktadır. Tıpta teşhis amacıyla çok kullanılmaktadır. Bu ilişki matrisinde X elemanını sınıf ya da hastalık olarak alırsak Y elemanını da bu sınıflara ya da hastalıklara ait öznelilik olarak alabiliriz. Yapılan tez çalışmasında X elemanı sınıf olarak Y elemanı da bu sınıflara ait AR (öz bağımlı) katsayılar olarak seçilmiştir. Benzer şekilde, Bölüm 5’de 6 adet sınıfı 4 adet AR katsayısıyla ilişkilendiren 6x4’lük bir BİM (bu matrise bundan sonra Rd matrisi denecektir) oluşturulacaktır.

3.4 Üyelikler Arasındaki Uzaklık

Yukarıda da ifade edildiği gibi Rd bir sistemi temsil eden sabit bir matris olabilmektedir. Bu bölümde sabit matris Rd oluşturularak üyelik fonksiyonundan elde edilecek üyelik değerlerinden Euclid uzaklıkları hesap edilecektir. Bunun

sonucunda elde edilecek uzaklık değerlerinin küçük olanı kullanılır. Bu değere Benzemezlik Ölçüsü denir [1],[7].

Rd matrisini bir sistemi temsil eden bir matris olarak ifade etmiştik. Bu matris o konuyla ilgili uzmanlarca oluşturulur. Bu matris, eğer işaret sınıflama veya tıpta teşhis amacıyla kullanılacaksa; sınıf veya hastalık için özneliliklerin alabilecekleri optimum değerleri veya önem derecelerini göstermesi bakımından büyük önem taşır.

Uzaklık veya başka bir ifadeyle Benzemezlik Ölçüsünün ifadesi

$$D_j(Rd_j, R) = \left(\sum_{i=1}^p |u_{Rd_j}(y_i) - u_R(y_i)|^s \right)^{1/s} \quad (3.11)$$

şeklindedir. Bu ifadede Rd (Sabit İlişki Matrisi) ve R (Üyelik değerlerinden elde edilen ilişki matrisi) ilişki matrisleri, $u_{Rd_j}(y_i)$ ve $u_R(y_i)$ ise Rd ve R'nin y_i parametresi için alacakları üyelik değerlerini göstermektedir. Burada i de parametre sayısını başka bir ifadeyle de öznelilik sayısını ifade eder ($i=1, \dots, p$). j ise sınıf sayısını göstermektedir. $D_j(Rd_j, R)$ ise j.'inci sınıf için uzaklık ifadesidir. Buradaki ifadede Minkowski uzaklık ifadesi kullanılmıştır. Eğer $s=2$ alınırsa Euclid uzaklığı elde edilmiş olur.

Yapılan çalışmada her bir sınıf için özneliliklerin en iyi değeri; yani alabilecekleri değerlerin en yükseği "1" dir. Bu durumda o işaret, o sınıfa tam ait olur ve 6x4'lük Rd matrisi her satır ve sütunda sadece bir adet bir olacak şekilde (yani bir permütasyon matrisi olarak) seçilir. Ancak bu konuda uzman kişilerden daha iyi bir Rd matrisi elde edilebilir. Yine çalışmada $s=2$ alınarak Euclid uzaklığı kullanılmıştır.

3.5 Üyelik Değerlerinin Elde Edilmesi

Yukarıda izah etmeye çalıştığımız işlemleri gerçekleştirebilmemiz için üyelik değerine ihtiyaç vardır. Yeni bir veri (x) üyelik değeri ya bir üyelik fonksiyonu aracılığı ile ya da mevcut veriden interpolasyon veya ortalama işlemleri sonucunda bulunur. En çok sıkıntı çekilen konulardan bir tanesi budur; uygun bir üyelik fonksiyonunun tesbiti için şu ana kadar bir çok yol önerilmiştir [5],[9],[12],[13]. Ancak daha önce de belirttiğimiz gibi en iyi üyelik fonksiyonu o konudaki uzman



kişilerce oluşturulur. Son yıllardaki literatürde kullanılan iki üyelik fonksiyonu şöyledir:

1- L.A.Zadeh ve daha sonra da bir çok araştırmacı tarafından kullanılan üyelik fonksiyonu şu şekilde verilmektedir:

$$u(x) = \frac{1}{1 + \left[\frac{x-a}{b} \right]^2} \quad (3.12)$$


Bu fonksiyonda a ve b belirlenmesi gereken parametreler olup çalışmada a, ortalama; b de standart sapma olarak alınmıştır[20].

2- Bortolan, Degani ve bir çok araştırmacı tarafından kullanılan üyelik fonksiyonu da aşağıdaki denklemle ifade edilir:

$$u(x) = \begin{cases} 0 & x \leq a \\ 1 - \left[\left(\frac{x-b}{b-a} \right)^2 \right]^s & a < x \leq b \\ 1 - \left[\left(\frac{x-b}{c-b} \right)^2 \right]^s & b \leq x < c \\ 0 & x \geq c \end{cases} \quad (3.13)$$

Yine bu fonksiyonda da a, b, c ve s belirlenmesi gereken parametrelerdir. Buradaki üyelik fonksiyonunda s=0.5 için ÜÇGEN üyelik fonksiyonu oluşmaktadır. Bu fonksiyonda s=0.5 için 1/(b-a) ile -1/(c-b) eğrinin sol ve sağındaki eğimleri ifade etmektedir [9].

Bu tezde yeni verilerin üyelik değerleri etiketlenmiş verilerin ağırlıklı ortalaması alınarak bulunmuştur. Bu yöntemin ayrıntıları Bölüm 4’de verilecektir.



4. BULANIK SINIFLAYICILAR VE İLİŞKİ MATRİSİ

Bu bölümde literatürde mevcut olan (K-EYK) sınıflayıcıları hakkında bilgi verilecek, bu tezin ileri sürdüğü Bulanık K-EYK (BK-EYK) tabanlı Bulanık İlişki Matrisi (BİM) anlatılacak ve bu matris kullanılarak oluşturulan sınıflayıcı tanıtılacaktır. Bir örnek veri seti üzerine anlatılacak sınıflayıcılar uygulanarak her sınıflayıcının özellikleri ortaya çıkarılmaya çalışılacaktır.


Bölüm 4.1’de örnek veri seti tanıtılacaktır. Literatürde mevcut olan K-EYK sınıflayıcıları, keskin ve bulanık olmak üzere iki kategoride Bölüm 4.2’de ele alınacaktır. Son olarak Bölüm 4.3’de BK-EYK tabanlı BİM sınıflayıcısı tanıtılacaktır.

4.1 Örnek Veri Seti

Örnek olarak iki sınıf alalım. Bu sınıflar ▲ ve O sınıfı olsun ve her bir sınıfta dört işaret olsun. Bilinmeyen yani etiketlenmemiş işareti de ■ sembolü ile belirtelim. Her işareti iki öznitelik (a_1 , a_2) ile belirtelim. Bu şekilde oluşturulan veri setindeki dokuz işaret için öznitelik değerleri Tablo 4.1’de verilmiştir ve grafik olarak işaretlerin (a_1 , a_2) öznitelik düzlemindeki yerleri Şekil 4.1’de gösterilmiştir. Bu şekilden de görüldüğü üzere etiketlenmemiş işaret iki sınıftan birine açık şekilde üye değildir. Veri seti oluşturulurken böyle sınıflanması zor bir etiketlenmemiş işaret kasıtlı olarak seçilmiştir. Bu seçimle değişik algoritmaların farklarının daha kolay gözleneceği düşünülmüştür.

Tablo 4. 1 Örnek Veri Seti

	a_1	a_2
▲	1	0,6
▲	1	1
▲	1,2	0,8
▲	1,3	0,5
O	1,65	0,8
O	1,7	1,2
O	1,8	0,7
O	1,85	1
■	1,4	1,15



Şekil 4. 1 Örnek Veri Setinin Grafiği

4.2. Mevcut K-EYK Sınıflayıcıları

Bu bölümde Keskin K-EYK, ve BK-EYK sınıflayıcıları tanıtılmış ve bu sınıflayıcılar örnekler üzerinde kullanılarak ve sınıflama performansları arasındaki farklar gösterilmiştir.

4.2.1 Keskin K-EYK Sınıflayıcısı

Keskin K-EYK sınıflayıcısı [9] en etkin sınıflama algoritmalarından birisidir. Herhangi bir ön kabul yapılmadan ve etiketlenmiş işaretler bir ön işleminden geçirilmeden, etiketlenmemiş bir işareti sınıflamak için kullanılabilir. Bu sınıflayıcının ilk aşamasında etiketlenmemiş bir işaretin etiketlenmiş işaret vektörlerinin herbirine olan Euclid uzaklıkları (4.1) ifadesi ile bulunur.

$$d_{ij} = \|x - x_{ij}\| \quad (4.1.)$$

Bu ifadede x etiketlenmemiş işaret, x_{ij} ise i 'inci sınıfın j 'inci işaretidir. İkinci aşamada bu uzaklıklar küçükten büyüğe doğru sıralanırlar ve bunlardan ilk K tanesi seçilir. Bu nedenle K , en yakın komşu sayısı olarak adlandırılır. K en yakın komşu içinde etiketlenmiş işaretlerin sınıflarından hangisinin sayısı fazla ise etiketlenmemiş işaret o sınıfa atanır.

Algoritma 4.1: Keskin K-En Yakın Komşuluk Sınıflayıcısı

Adım-1: En yakın komşuluk sayısı K 'yı seç.

Adım-2: Etiketlenmemiş işareti (x) yükle ve etiketlenmiş işaretlerin herbirinden olan Euclid uzaklıklarını (4.1) ifadesi yardımıyla hesapla.

Adım-3: Hesaplanan uzaklıkları küçükten büyüğe doğru sırala ve bunlardan “ilk K tane” sini tut.

Adım-4: K en yakın komşu içinde en fazla elemana sahip olan sınıfı ($C_{\max}$) bul.

Adım-5: Etiketlenmemiş işareti $C_{\max}$ sınıfına ata.

Algoritma 4.1’in örnek veri setine uygulanmasından elde edilen veriler Tablo 4.2’de verilmiştir. Tablo 4.2(a)’da ikinci adımın sonucu verilmiştir. Burada hesaplanan uzaklıklar sıralanarak Tablo 4.2(b) elde edilmiştir.

Tablo 4. 2 (a)Keskin K-EYK Sınıflayıcısı İçin Euclid Uzaklığı Hesabı ve Sıralanması

Sınıf	a1	a2	Euclid uzaklığı	d_{ij}
▲	1	0,6	$(1,4-1)^2+(1,15-0,6)^2$	0,4625
▲	1	1	$(1,4-1)^2+(1,15-1)^2$	0,1825
▲	1,2	0,8	$(1,4-1,2)^2+(1,15-0,8)^2$	0,1625
▲	1,3	0,5	$(1,4-1,3)^2+(1,15-0,5)^2$	0,4325
O	1,65	0,8	$(1,4-1,65)^2+(1,15-0,8)^2$	0,185
O	1,7	1,2	$(1,4-1,7)^2+(1,15-1,2)^2$	0,0925
O	1,8	0,7	$(1,4-1,8)^2+(1,15-0,7)^2$	0,3625
O	1,85	1	$(1,4-1,85)^2+(1,15-1)^2$	0,225

Tablo 4. 2 (b) Komşuluk ile değişen sınıflama sonuçları

Sınıf	d^*	
O	0,0925	K=1 için ■ sınıfı bilinmeyen işaret O sınıfına atanır.
▲	0,1625	K=2 için ■ sınıfı bilinmeyen işaret ▲ sınıfına atanır.
▲	0,1825	K=3 için ■ sınıfı bilinmeyen işaret ▲ sınıfına atanır.
O	0,185	K=4 için ■ sınıfı bilinmeyen işaret O sınıfına atanır.
O	0,225	K=5 için ■ sınıfı bilinmeyen işaret O sınıfına atanır.
O	0,3625	
▲	0,4325	
▲	0,4625	

Bu örnekte de görüldüğü üzere K yakın komşuluk sayısının seçimi büyük önem taşımaktadır. K etiketlenmiş işaret sayısı kadar da seçilebilir. Ancak bu seçim çok fazla işlem yapılmasına neden olur ki bu da zaman alır. On-line işaret sınıflamalarında bu durum pek tercih edilmez.

Keskin K-EYK sınıflayıcısının bir dezavantajı da bu örnekte ortaya çıkmaktadır. Seçilen herhangi bir K sayısı için sınıflamanın ne kadar kesin olduğu görülmemektedir. Örneğin yukarıda etiketlenmemiş işaret açık olarak sınıflanması zor bir işarettir. Fakat tek bir K sayısı seçildiğinde bu sınıflama zorluğu ortaya çıkmamaktadır. Bu zorluk ancak ardışık birkaç K değeri ile yapılan sınıflamalardaki

kararsızlığa bakıldığında fark edilebilir. $K=2$ ve $K=4$ için sınıflama sonucu bilgisayar tarafından rasgele yapılan atamadır. Yani bu değer doğru bir sınıflama sonucu olmayabilir.

4.2.2. Bulanık K-EYK Sınıflayıcısı

Görüldüğü üzere keskin K-EYK sınıflayıcısı bir işaretin sınıflanmasındaki zorluğu göstermemektedir. Çünkü, işaretin bir sınıfa aitliliği 1 ya da 0 olarak alınmaktadır. Bununla beraber eğer üyelik dereceleri kullanılacak olursa işaretin yakın komşuluk sayısı çok olan bir sınıfa ait üyelik değerleri, yakın komşuluk sayısı az olan bir sınıfın üyeliklerinden küçük olabilir. Bu durumu giderebilmek için bulanık algoritmalarla atanan üyelik değerleri kullanılır. Böylece hem işaret sınıflanmış olur hem de işaretin her bir sınıfa olan aitlik (üyelik) derecesi hakkında bilgi sahibi olunur. Dolayısıyla sınıflanmış işaretle ilgili daha çok bilgi elde edilir. BK-EYK sınıflayıcısı, bilinmeyen bir işareti bir sınıfa atamanın ötesinde o sınıfa ne kadar aittir sorusuna da cevap verir.

Bulanık K-EYK sınıflayıcısında etiketlenmemiş bir işaretin i 'inci sınıf için üyelik değeri (u_i), belirlenen K adet yakın komşunun daha önceden atanmış i 'inci sınıf üyelik değerlerinin ortalamasının alınması ile bulunur. En basit şekilde, etiketlenmemiş x işaretinin i 'inci sınıfa üyelik değeri (4.2) ifadesiyle bulunur.

$$u_i(x) = \sum_{j=1}^K \frac{u_{ij}}{K} \quad ; i=1, \dots, C \quad (4.2)$$

Burada u_{ij} , x bilinmeyen işaretinin j 'inci en yakın komşusunun i 'inci sınıfa üyelik değeridir ve C toplam sınıf sayısıdır. Denklem (4.2)'de alınan ortalamada etiketlenmiş işaretlerin etiketlenmemiş işarete uzaklığı dikkate alınmamıştır. Bunun yerine (4.3)'de verilen uzaklığa bağlı ağırlıklı ortalama formülü ile daha sağlıklı bir üyelik değeri hesaplanabilir[19].

$$u_i(x) = \frac{\sum_{j=1}^K \frac{u_{ij}}{d_j}}{\sum_{j=1}^K \frac{1}{d_j}} \quad ; i=1, \dots, C \quad (4.3)$$

Burada $d_j = \|x - x_j\|$ etiketlenmemiş işaretin en yakın j 'inci komşusuna olan Euclid uzaklığıdır. Bu tezde etiketlenmemiş işaretin üyelik değeri (4.3)'de verilen ağırlıklı ortalama ile hesaplanmıştır.

Yukarıdaki ortalamalarla bulunan üyelik değerlerine bakılarak sınıflama yapmanın değişik yolları vardır. Eşik değeri kullanılarak veya etiketlenmemiş işaretin en yüksek üyelik değerine bakılarak bir sınıfa atama yapılabilir. Bu çalışmada en yüksek üyelik değerine bakılarak sınıflama yapılmıştır.

Algoritma 4.2: Bulanık K-En Yakın Komşuluk Sınıflayıcısı

Adım-1: En yakın komşuluk sayısı K 'yı seç.

Adım-2: Etiketlenmemiş işareti (x) yükle ve etiketlenmiş işaretlerin her birinden olan Euclid uzaklıklarını (4.1) ifadesi yardımıyla hesapla.

Adım-3: Hesaplanan uzaklıkları küçükten büyüğe doğru sırala ve bunlardan "ilk K " tanesini tut.

Adım-4: K tane uzaklığın hesaplandığı etiketlenmiş işaret vektörlerine her sınıf için karşılık gelen üyelik değerlerini dosyadan oku ve bu değerleri kullanarak (4.3) ifadesi yardımıyla etiketlenmemiş işaretin her sınıf için üyelik değerini ($u_i(x)$, $i=1, \dots, C$) hesap et.

Adım-5: $\max_i (u_i(x))$ değerini veren i sınıfına işareti ata.

Bu algoritma örnek veri setine uygulandığında d_{ij} uzaklığı sınıfları belirten bir sınıf matrisi ile eşleştirilip bu matris ile birlikte küçükten büyüğe doğru sıralamada (d_{ij}^*) yapılır (bkz şekil 4.2). Bu örnekte etiketlenmiş işaret için üyelik değeri keskin olarak verilmiştir. Yani $\blacktriangle$ sınıfına ait bir işaretin bu sınıfa aitliği 1, O sınıfına olan üyelik değeri de 0 olarak alınmıştır. (4.3) denklemini kullanılarak etiketlenmemiş verinin üyelik değeri değişik K komşulukları için şöyle bulunur:

d_{ij}	$\blacktriangle$	O		d_{ij}^*	$\blacktriangle$	O
0,4625	1	0	Sıralama $\rightarrow$	0,0925	0	1
0,1825	1	0		0,1625	1	0
0,1625	1	0		0,1825	1	0
0,4325	1	0		0,185	0	1
0,185	0	1		0,225	0	1
0,0925	0	1		0,3625	0	1
0,3625	0	1		0,4325	1	0
0,225	0	1		0,4625	1	0

Şekil 4. 2 Her Bir Öznitelik İçin Euclid Uzaklıkları ve Sıralanması

K=1 için

$$u_1 = u_{\Delta} = \frac{\left(0 \times \frac{1}{0,0925}\right)}{\left(\frac{1}{0,0925}\right)} = 0$$

$$u_2 = u_O = \frac{\left(1 \times \frac{1}{0,0925}\right)}{\left(\frac{1}{0,0925}\right)} = 1$$

■ etiketlenmemiş işaret O sınıfına atanır.

K=2 için

$$u_1 = u_{\Delta} = \frac{\left(0 \times \frac{1}{0,0925}\right) + \left(1 \times \frac{1}{0,1625}\right)}{\left(\frac{1}{0,0925} + \frac{1}{0,1625}\right)} = 0,362745$$

$$u_2 = u_O = \frac{\left(1 \times \frac{1}{0,0925}\right) + \left(0 \times \frac{1}{0,1625}\right)}{\left(\frac{1}{0,0925} + \frac{1}{0,1625}\right)} = 0,637255$$

En büyük üyelik değerine bakılarak ■ etiketlenmemiş işaret O sınıfına atanır.

K=3 için

$$u_1 = u_{\Delta} = \frac{\left(0 \times \frac{1}{0,0925}\right) + \left(1 \times \frac{1}{0,1625}\right) + \left(1 \times \frac{1}{0,1825}\right)}{\left(\frac{1}{0,0925} + \frac{1}{0,1625} + \frac{1}{0,1825}\right)} = 0,518323$$

$$u_2 = u_O = \frac{\left(1 \times \frac{1}{0,0925}\right) + \left(0 \times \frac{1}{0,1625}\right) + \left(0 \times \frac{1}{0,1825}\right)}{\left(\frac{1}{0,0925} + \frac{1}{0,1625} + \frac{1}{0,1825}\right)} = 0,481677$$

En büyük üyelik değerine bakılarak ■ etiketlenmemiş işaret ▲ sınıfına atanır.



K=4 için

$$u_1 = u_{\Delta} = \frac{\left(0 \times \frac{1}{0,0925}\right) + \left(1 \times \frac{1}{0,1625}\right) + \left(1 \times \frac{1}{0,1825}\right) + \left(0 \times \frac{1}{0,185}\right)}{\left(\frac{1}{0,0925} + \frac{1}{0,1625} + \frac{1}{0,1825} + \frac{1}{0,185}\right)} = 0,41772$$

$$u_2 = u_O = \frac{\left(1 \times \frac{1}{0,0925}\right) + \left(0 \times \frac{1}{0,1625}\right) + \left(0 \times \frac{1}{0,1825}\right) + \left(1 \times \frac{1}{0,185}\right)}{\left(\frac{1}{0,0925} + \frac{1}{0,1625} + \frac{1}{0,1825} + \frac{1}{0,185}\right)} = 0,58228$$

En büyük üyelik değerine bakılarak ■ etiketlenmemiş işaret O sınıfına atanır.

Etiketlenmemiş işaret, BK-EYK sınıflayıcısı kullanarak elde edilen üyelik değeri en büyük olan sınıfa atandığında sonuçların keskin K-EYK sınıflayıcısı kullanılarak elde edilen sonuçlarla aynı olduğu görülür. Fakat bulunan üyelik değerlerinin birbirlerine yakın olması verilen herhangi bir K komşuluk değeri için sınıflamanın zor olduğunu gösterir. Bu durum, eşik değeri ile sınıflama kullanılsaydı daha belirgin olarak gözlenirdi. Örneğin bir sınıfa atama yapılabilmesi için 0,7'lik eşik değerinin üzerinde bir üyelik değeri şart koşulsaydı (K=1 durumu dışında) etiketlenmemiş işaretin iki sınıfa da atanamadığı gözlenecekti.

BK-EYK sınıflayıcısının ve keskin K-EYK sınıflayıcısının sınıflama performansını bozan özniteliklerin tespitinde etkin olmadığı açıktır. Her özniteliğin ayrı değerlendirildiği bir sınıflama algoritması kullanıldığında performansa etki eden özniteliklerin tespiti mümkün olacaktır. Bu ise sınıflamanın daha sağlıklı olmasını sağlayacaktır.

4.3 BK-EYK Tabanlı BİM Sınıflayıcısı

Bu sınıflayıcının BK-EYK sınıflayıcısı ile işleyiş mantığı aynıdır. Fakat farklı olarak BK-EYK sınıflayıcısındaki üyelik değeri bulma işlemi, bu algorithmada herbir öznitelik için ayrı ayrı gerçekleştirilir ve sınıflama sonucu BİM üzerinden yapılır. Burada yine Euclid uzaklığı kullanılmaktadır. Böylece herbir özniteliğin herbir sınıf için üyelik değeri (4.3) kullanılarak hesaplanmaktadır. Ancak burada üyelik değeri özniteliğe ait olduğu için bulunan değer iki indisle gösterilir. Yani $u_{ij}(x)$, x işaretinin j'inci özniteliğinin i'inci sınıfa üyelik değerini gösterir. Bu üyelik değerleri satırları



sınıfları, sütunları da öznitelikleri gösteren BİM matrisi olarak bir araya toplanır. Bulanık ilişki matrisi $i=1,...,C$ (C =Sınıf Sayısı) ve $j=1,...,N$ (N =Öznitelik Sayısı) için (4.4)'deki gibi tanımlanır.

$$R_F(x) = \begin{bmatrix} u_{11}(x) & \dots & u_{1j}(x) & \dots & u_{1N}(x) \\ \dots & \dots & \dots & \dots & \dots \\ u_{i1}(x) & \dots & u_{ij}(x) & \dots & u_{iN}(x) \\ \dots & \dots & \dots & \dots & \dots \\ u_{C1}(x) & \dots & u_{Cj}(x) & \dots & u_{CN}(x) \end{bmatrix} \quad (4.4)$$

Bir işaret için bu matris hesap edildikten sonra, işaretin hangi sınıfa ait olduğunun tespit edilmesi için aşağıdaki adımlar takip edilir:

1- $R_F(x)$ matrisinin her bir satırında MAX (Maksimum) işlemi yaparak her bir sınıf için o sınıfı temsil eden üyelik derecesi bulunur.

2- Birinci adım sonucunda $R_F(x)$ matrisi tek sütunlu ve C satırlı bir matris haline gelir. Bu matris üzerinde tekrar MAX işlemi yapılarak hangi satırda en büyük değer elde ediliyorsa işaret o sınıfa atanır.

Algoritma 4.3: BK-EYK Tabanlı BİM Sınıflayıcısı

Adım-1: En yakın komşuluk sayısı K 'yı seç.

Adım-2: Tek bir özniteliği al.

Adım-3: Her bir etiketlenmiş işaret için öznitelikler arası Euclid uzaklığını bul.



Adım-4: Uzaklıkları küçükten büyüğe doğru sırala .

Adım-5: K en yakın komşuluğu ve Denklem (4.3) ile üyelik değerlerini hesapla

Adım-6: Diğer öznitelikler için de $R_F(x)$ matris elemanlarını tamamlayıncaya kadar adım 2-5'i tekrar et.

Adım-7: Bu matrisin satırlarında ve sütunda MAX işlemini uygula ve sınıflama sonucuna ulaş.

Şekil 4.3'de blok diyagramı verilen bu algoritmayı örnek sete uygularsak:



$1 \leq i \leq p$: Model Parametresi veya Öz nitelik sayısı (4)

$1 \leq j \leq c$: Sınıf sayısı (6)

Şekil 4.3 BK-EYK Tabanlı BİM Sınıflayıcısının Blok Diyagramı.

a1 ve a2 özniteliklerinin tek tek ele alarak uzaklıkları hesaplayalım.

Tablo 4.3 Her Bir Öznitelik İçin Euclid Uzaklıkları ve Sıralaması

da1	▲	O	da1*	▲	O
0,16	1	0	0,01	1	0
0,16	1	0	0,04	1	0
0,04	1	0	0,0625	0	1
0,01	1	0	0,09	0	1
0,0625	0	1	0,16	1	0
0,09	0	1	0,16	1	0
0,16	0	1	0,16	0	1
0,2025	0	1	0,2025	0	1

da2	▲	O	da2*	▲	O
0,3025	1	0	0,0025	0	1
0,0225	1	0	0,0225	1	0
0,1225	1	0	0,0225	0	1
0,4225	1	0	0,1225	1	0
0,1225	0	1	0,1225	0	1
0,0025	0	1	0,2025	0	1
0,2025	0	1	0,3025	1	0
0,0225	0	1	0,4225	1	0

(4.3) denkleminde Tablo 4.3'deki değerler yerine konularak

K=2 için

$U_{\blacktriangle}(a1)$	1	$U_O(a1)$	0
$U_{\blacktriangle}(a2)$	0,1	$U_O(a2)$	0,9

üyelik değerleri elde edilir.

$$\begin{bmatrix} U_1(a1) & U_2(a1) \\ U_1(a2) & U_2(a2) \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0,1 & 0,9 \end{bmatrix} \Rightarrow \text{satır max} = \begin{bmatrix} 1 \\ 0,9 \end{bmatrix} \Rightarrow \text{Sütun max} = 1$$

Sınıfı bilinmeyen işaret K=2 komşuluğunda ▲ sınıfına atanır

K=3 için

$U_{\blacktriangle}(a1)$	0,886525	$U_O(a1)$	0,113475
$U_{\blacktriangle}(a2)$	0,090909	$U_O(a2)$	0,909091

$$\begin{bmatrix} U_1(a1) & U_2(a1) \\ U_1(a2) & U_2(a2) \end{bmatrix} = \begin{bmatrix} 0,886525 & 0,113475 \\ 0,090909 & 0,909091 \end{bmatrix} \Rightarrow \text{satır max} = \begin{bmatrix} 0,886525 \\ 0,909091 \end{bmatrix}$$

$Sütun\ max = 0,909091$

Sınıfı bilinmeyen işaret K=3 komşuluğunda O sınıfına atanır

K=4 için

$U_{\blacktriangle}(a1)$	0,821768	$U_O(a1)$	0,178232
$U_{\blacktriangle}(a2)$	0,105839	$U_O(a2)$	0,894161

$$\begin{bmatrix} U_1(a1) & U_2(a1) \\ U_1(a2) & U_2(a2) \end{bmatrix} = \begin{bmatrix} 0,821768 & 0,178232 \\ 0,105839 & 0,894161 \end{bmatrix} \Rightarrow satır\ max = \begin{bmatrix} 0,821768 \\ 0,894161 \end{bmatrix}$$

$Sütun\ max = 0,894161$

Sınıfı bilinmeyen işaret K=4 komşuluğunda O sınıfına atanır

BK-EYK tabanlı BİM sınıflayıcısının diğer K-EYK sınıflayıcılarından farklı yanı her bir özniteliğin sınıflarla bağlantısını göstermesidir. Yukarıdaki örnekte de a1 özniteliğinin $\blacktriangle$ sınıfına atamada baskın olduğu, a2 özniteliğinin ise O sınıfına atamada baskın olduğu gözlenmektedir. Bu ise diğer sınıflayıcılardan fazla olarak etiketlenmemiş işaretin niye zor sınıflandığını açıklar: Etiketlenmesi istenen işareti oluşturan iki özniteliğin her biri değişik sınıflara yakındır.

5. SINIFLAMA SONUÇLARI

Bir önceki bölümde BK-EYK tabanlı BİM sınıflayıcısı anlatıldı ve bir örnekte diğer K-EYK sınıflayıcılardan farkı gösterildi. Bu bölümde bu sınıflayıcı Bölüm 2.5’de anlatıldığı üzere toplanan EMG işaretlerine uygulandığında elde edilen başarı gösterilecek ve literatürde bulunan iki değişik sınıflayıcının başarıları ile karşılaştırılacaktır. Bölüm 2.5.1’de anlatıldığı üzere 6 kol hareketi ile elde edilen EMG işaretleri ele alınmış ve bu işaretler 4 öznitelik kullanılarak modellenmiştir. Dolayısı ile BİM matrisi (Sınıf Sayısı= $C=6$, Öznitelik Sayısı= $N=4$ olarak) 6×4 boyutludur. Sınıflamayı gerçekleştirdiğimiz veri seti etiketlenmiş yani sınıfı belli veri setidir. Bu veri setinin her bir öznitelik kümesini ele alarak ve üyelik fonksiyonları yardımıyla $R_F(x)$ matrisi oluşturularak sınıflama gerçekleştirilir. Bu yöntemle her seferinde bir veri kümesi etiketi bilinmiyormuş gibi sınıflamaya tabi tutulur. Bu şekilde yapılan sınıflama analizine birini hariç tut (**Leave-One-Out**) yöntemi denir. Diğer yöntemler kullanıldığında üyelik fonksiyonları ya eldeki mevcut veriler gözönüne alınarak bulunmakta ya da bu konuda uzman kişilerin yardımı ile elde edilmektedir [12]. Bu her iki durum da bir ön çalışmayı gerektirmekte ve hata payını yükseltmektedir. Leave-One-Out yönteminde ise hiçbir ön işleme veya varsayım gerekliliği kalmamaktadır.

Bölüm 2.5.1’de belirtildiği üzere elimizde 72 veri olduğuna göre Leave-One-Out yönteminde sınıflanması düşünülen veri 71 etiketlenmiş işaret göz önüne alınarak sınıflanmıştır. Sınıflanmış verinin gerçekte hangi sınıfa ait olduğu bilindiği için kullanılan sınıflayıcının performansı 72 verinin kaç tanesinin doğru sınıflandığına bakılarak ölçülebilir.

5.1 Keskin K-EYK ve BK-EYK Sınıflayıcısı

Tüm öznitelikler kullanılarak sınıflama gerçekleştirilmiş ve sonuçlar Tablo 5.1’de verilmiştir.

Tablo 5.1 BK-EYK ve Keskin K-EYK Sınıflayıcısının Performansı

K	BK-EYK	Keskin K-EYK
2	46	46
3	48	49
4	48	48
5	48	46
6	49	52

Tablo 5.1’de görüleceği üzere özniteliklerin tamamını kullanarak yapılan sınıflamalarda sınıflama performansı komşuluk sayısına göre değişmektedir. Yine bu tablodan BK-EYK tabanlı sınıflayıcıda komşuluk sayısının artması ile sınıflama performansının artmıştır. Keskin K-EYK sınıflayıcısında ise düzensiz sınıflama sonuçları elde edilmiştir. Bütün öznitelikler alınarak yapılan sınıflamada sınıflamayı olumsuz etkileyen öznitelikler ayırt edilememektedir. Bu tablodan keskin K-EYK sınıflayıcısının komşuluk sayısı ile değişen BK-EYK ya göre biraz üstün performans gösterdiği anlaşılmaktadır. BK-EYK sınıflayıcısının elde edilen sınıflama sonuçlarının hangi sınıfa ne kadar yakın olduğunu göstermesi önemlidir. BK-EYK için en yüksek sınıflama performansı 49 doğru sınıflamadır. Buna karşılık Keskin K-EYK için en yüksek sınıflama performansı 52 doğru sınıflamadır.

Kullanılan öznitelikler ikişer ikişer alınarak BK-EYK ve Keskin K-EYK sınıflayıcısının bütün öznitelik kombinasyonları denenmiş ve sonuçları Tablo 5.2 de gösterilmiştir..

Tablo 5.2 BK-EYK ve Keskin K-EYK Sınıflayıcısının Performansı

	a1 & a2		a1 & a3		a1 & a4		a2 & a3		a2 & a4		a3 & a4	
K	B	C	B	C	B	C	B	C	B	C	B	C
2	45	49	49	48	46	46	46	45	47	44	38	43
3	47	43	50	49	47	47	47	50	50	42	41	43
4	47	50	50	48	46	50	49	46	48	45	41	40
5	46	46	50	47	45	47	48	43	47	44	39	41
6	44	48	51	50	46	44	49	48	48	46	40	41

Tablo 5.2 ye bakarak K=6 için a1 ve a3 öznitelikleri birlikte kullanılarak Keskin K-EYK sınıflayıcısı ile 72 verinin 50’si sınıflanmıştır. Bu sınıflama sonucu keskin sınıflayıcıları için en iyi sınıflama performansını göstermektedir. Yine Tablo 5.2 ye bakarak K=6 için a1 ve a3 öznitelikleri birlikte kullanılarak BK-EYK için 51 veri doğru sınıflanmıştır. BK-EYK için bu sınıflama en yüksek performans olmuştur.

Tablo 5.2 ye bakılarak sınıflama performansı en yüksek olan sınıflayıcı BK-EYK sınıflayıcısıdır. Her K değeri için bu genelleme yapılamamaktadır. En kötü sınıflama a3 ve a4 için elde edilmiştir. K=2 için a3 ve a4 BK-EYK sınıflayıcılarında 38 doğru sınıflama performansı ile en kötü sınıflama sonucunu vermiştir. K=4 için a3 ve a4 öznitelikleri ile yapılan sınıflamada 40 doğru sınıflama ile en kötü keskin K-EYK sınıflayıcısı performansı elde edilmiştir.

5.2 BK-EYK tabanlı BİM Sınıflayıcısı

Örneklerde görülen “K” komşuluk sayısı’nı göstermektedir. Tablo 5.3’de tüm öznitelikler kullanılarak sonuçlar alınmıştır. Bu tablodan gözleneceği üzere bu tezdeki BK-EYK tabanlı BİM sınıflayıcısı sınıflama performansı en yüksek sınıflayıcıdır. BK-EYK sınıflayıcısında komşuluk sayısı K=2 olması durumunda en iyi sonucun alındığı anlaşılmıştır. Bütün öznitelikler kullanılarak ve BİM yardımıyla Tablo 5.3 oluşturulmuştur.

Tablo 5.3 BK-EYK-BİM ve Keskin K-EYK BİM Sınıflayıcısının Performansı

K	BK-EYK-BİM	Keskin K-EYK
2	71	52
3	70	47
4	70	47
5	70	38
6	70	36

Tablo 5.3 de K değeri arttıkça keskin K-EYK sınıflayıcısının sınıflama performansı düşmüştür. Sınıflama performansının düşmesine sebep BİM sınıflayıcısında elde edilen matrisin en yüksek sınıflamayı temsil eden “1” değerinin sayısının matris içinde artması ve bilgisayarın sınıflamayı yaparken rasgele bir değer seçmesi gelmektedir.

Tablo 5.4’de görülen sınıflama sonuçları ise kullanılan özniteliklerin ikişer ikişer alınarak bütün kombinasyonların denenmesi ile elde edilmiştir. Tablo 5.4’e bakılarak sınıfları temsil eden en etkin öznitelik tesbit edilmeye çalışılmıştır. Bu tablodan görüldüğü gibi EMG işaretlerine ait bu altı sınıfı (kol hareketlerini) temsil edebilmek için a1 ve a2 özniteliklerinin yeterli olduğuna karar verilebilir. Dolayısı ile 4 boyut yerine 2 boyutlu bir sistemin kullanılması daha uygun olur. Bu hem bellek hem de hız yönünden yararlı olacaktır. Hatta a3 ve a4 özneliğinin dahil edilmesi

sınıflama performansının düşmesine sebep vermektedir. Tablo 5.4'nin elde edilmesinde BİM kullanılmıştır. Bu tablolarda K=Komşuluk Sayısı B=Bulanık Sınıflayıcı C=Keskin Sınıflayıcı olarak alınmıştır.

Tablo 5.4 BK-EYK-BİM ve Keskin K-EYK BİM Sınıflayıcısının Performansı

	a1 & a2		a1 & a3		a1 & a4		a2 & a3		a2 & a4		a3 & a4	
K	B	C	B	C	B	C	B	C	B	C	B	C
2	72	60	69	45	71	52	69	45	71	52	71	52
3	72	57	69	42	71	47	69	42	71	47	71	47
4	72	55	69	42	71	47	69	42	71	47	71	47
5	72	54	69	38	71	38	69	38	71	38	71	38
6	72	56	69	39	71	36	69	39	71	36	71	36

Tablo 5.4 de BK-EYK tabanlı BİM sınıflayıcısı a1 ve a2 öznitelikleri alınarak yapılan sınıflamada bütün K değerleri için 72 verinin tamamını sınıflamıştır. Bu sınıflama performansı %100 dür. En düşük BK-EYK tabanlı BİM sınıflayıcısı ise 69 doğru veri sınıflamıştır. Bu sınıflama performansı %95,83 dür. En düşük Keskin K-EYK tabanlı BİM sınıflayıcı ise 36 doğru sınıflama ile K=6 için a1 ve a4, a2 ve a4, a3 ve a4 özniteliklerinin sınıflanmasından elde edilmiştir. a3 sınıflamayı olumsuz etkileyen bir özniteliktir. Bu özneliğin sınıfı kötü temsil etmesi verinin alınması sırasında kol hareketlerinden birinin aynı zamanda diğer sınıfı da temsil edebilecek değerler içermesinden kaynaklanabilir. a1 ve a2 özniteliklerinin sınıflamaları en iyi temsil eden öznitelikler olduğu görülmüştür.

Tablo 5.1, Tablo 5.2, Tablo 5.3 ve Tablo 5.4 ele alınarak yapılan sınıflama performansı karşılaştırılması Tablo 5.5 de verilmiştir.

Tablo 5.5 BİM kullanılarak ve kullanmadan sınıflamaların karşılaştırılması

	Bulanık İlişki Matrisi İle			
K	BK-EYK	K-EYK	BK-EYK	K-EYK
2	63.89	63.89	98.61	72.22
3	66.66	68.06	97.22	65.28
4	66.66	66.66	97.22	65.28
5	66.66	63.89	97.22	52.78
6	68.06	72.22	97.22	50.00

Tablo 5.5'e bakarak BK-EYK tabanlı BİM sınıflayıcısının her zaman üstün bir sınıflama performansına sahip olduğu söylenebilir. Keskin K- EYK tabanlı BİM sınıflayıcısı komşuluk sayısının artması ile sınıflama performansının düştüğü görülmektedir. BK-EYK sınıflayıcısı aratan K değeri ile sınıflama performansı artmaktadır. Keskin K-EYK sınıflayıcısı ile elde edilen sınıflama sonuçları en iyi sınıflamayı K=6 olduğu zaman vermiştir. Diğer K değerinde bu sınıflayıcı K'nın artışına bağlı olamayan sınıflama sonuçları vermiştir.

5.3 Bulanık En Yakın Üyelik Sınıflayıcısı

Bu sınıflama algoritmasının temel mantığı Enrique H.Ruspini tarafından ortaya koyulmuştur [10]. Bulanık En Yakın Üyelik (BEYÜ) sınıflama algoritması, etiketlenmemiş bir işareti veya sınırlı sayıdaki işaret grubunu eldeki mevcut etiketlenmiş işaret vektörleri ile en yakın üyelik ilişkisine bağlı olarak sınıflamayı amaç edinir. Bu algoritmanın BK-EYK algoritmasından farklı yönü şöyledir: BK-EYK'da etiketlenmiş ve birer üyelik değeri atanmış işaret vektörleri kullanılarak işaret sınıflamak için en yakın K adet işaretin üyeliklerinin herbir sınıf için ortalamasının (4.2 ifadesi) alınması söz konusudur. BEYÜ sınıflayıcısında ise etiketlenmiş haldeki bütün veriler ve bu verilere ait üyelik değerlerinin tamamı dikkate alınmakta olup öğrenme algoritmalarındakine benzer bir iterasyon ve minimizasyon tekniği ile etiketlenmemiş bir işaret veya işaret grubu üyelik değerleri ile sınıflanabilmektedir [20].

Bu yöntemde, q, etiketlenmemiş işaret sayısı olmak üzere bu işaretlerin C adet sınıfa üyelik değerleri (5.1) ifadesi minimize edilerek bulunur.

$$\hat{J}_R(u) = \sum_{i=1}^C \sum_{j=1}^q \sum_{k=1}^n \left(\|u_i(x_j) - u_i(x_k)\|^2 - \|x_j - x_k\|^2 \right)^2 \quad (5.1)$$

(5.1) ifadesinde Euclid normu kullanılmış olup x_j , j'inci etiketlenmemiş işareti; x_k , k'inci etiketlenmiş işareti; $u_i(x_j)$, etiketlenmemiş x_j vektörünün i'inci sınıfa üyelik değerini; $u_i(x_k)$ da etiketlenmiş x_k vektörünün i'inci sınıfa üyelik değerini göstermektedir. Bu ifadeyi minimum yapan üyelik değer/değerleri işaret/işaretlerin sınıflarını belirlemede kullanılır. Yapılan çalışmada q=1 alınarak herbir işaret sınıflamaya çalışılmıştır. Bu durumda minimize edilecek ifade şu hale gelir:

$$\hat{J}_R(u) = \sum_{i=1}^C \sum_{k=1}^n \left(\|u_i(x) - u_i(x_k)\|^2 - \|x - x_k\|^2 \right)^2 \quad (5.2)$$



Bu yöntem bütün işaretleri ve bu işaretlere ait üyelikleri ele almakta olup işleme sırasında uzun zaman almaktadır. Ancak, etkili bir yol olması tercih sebebi olmaktadır [11].

Yapılan çalışmanın BEYÜ ile karşılaştırılabilmesi için 1995 yılında Hüseyin Şeker tarafından yapılan yüksek lisans tez çalışmasında elde edilen değerler kullanılmıştır[22].

Toplam 72 verinin 48'i kullanılarak BEYÜ sınıflayıcısı performans tablosunda her bir sınıf için 12 farklı veri ele alınmıştır[22]. Burada elde edilen sonuçlar bulanık C ortalamaları (BCO) algoritması kullanılarak elde edilen sonuçlardır. Başka algoritmalar kullanılarak BEYÜ sınıflayıcısı ile sınıflama yapılabilir ve daha yüksek sınıflama sonuçlarına ulaşılabilir.

Tablo 5.6 BEYÜ Sınıflayıcısı İçin Elde Edilen Sınıflama Sonuçları

	Dinlenme	Bilek Döndürme	Kavrama	Bilek Bükme
Dinlenme	12/12	0/12	0/12	0/12
Bilek Döndürme	0/12	9/12	3/12	0/12
Kavrama	0/12	5/12	7/12	0/12
Bilek Bükme	0/12	0/12	1/12	11/12

Tablo 5.7 BEYÜ Sınıflayıcısı İçin Elde Edilen Doğru Sınıflama Sonuçları

	Dinlenme	Bilek Döndürme	Kavrama	Bilek Bükme
Doğru Sınıflama (BCO)	12/12	9/12	7/12	11/12

Tablo 5.7, Tablo 5.6 den elde edilen sonuçların doğru sınıflama yapılanların ayrıştırılması ile elde edilmiştir. Toplam doğru sınıflama %81,25 dir.



5.3 Yapay Sinir Ağları (Back Propagation Neural Network) Sınıflayıcısı

Bu bölümde [12]de verilen yapay sinir ağı kullanılmıştır. Yapay sinir ağları (Artificial Neural Network) sınıflayıcısında hata hedefi 0,1 seçilmekle birlikte zamandan kazanmak için her sınıflamada maksimum iterasyon sayısı 5000 olarak seçilmiştir. Ağ eğitilirken başlangıç değerler her bir işaretin sınıflanması sırasında aynı alınmıştır.

İlk olarak tüm öznitelikler (4 öznitelik) alınarak ağ eğitilmiştir. Bunun için 4 girişli ve 6 çıkışlı bir ağ seçilmiştir. Sadece bir saklı katman alınmış ve saklı katmandaki neuron sayısı da 6 olarak seçilmiştir. Bu ağı 4x6x6 olarak gösterebiliriz.

İkinci olarak tüm öznitelikler yerine yukarıdaki sonuçlarda elde edilen ve dominant öznitelik olarak bulduğumuz a1 ve a2 özniteliği alınarak ağ eğitilmiştir. Bunun için ise 2 girişli ve 6 çıkışlı bir ağ seçilmiştir. Sadece bir saklı katman alınmış ve saklı katmandaki neuron sayısı da 6 olarak seçilmiştir. Bu ağı ise 2x6x6 olarak gösterebiliriz.

4x6x6 ve 2x6x6 ağ yapısı için sınıflama sonuçları Tablo-5.8'de gösterilmiştir.

Tablo 5.8 ANN İle 2 Öznitelik ve 4 Öznitelik Kullanılarak Yapılan Sınıflama Sonuçları

ANN 4x6x6	ANN 2x6x6
44	46

ANN algoritması kullanılarak elde edilen 72 verinin doğru sınıflama performansı 46 dır. Bu değer %63,88 olarak ifade edilebilir. Yüzde olarak ANN keskin K-EYK ve BK-EYK dan daha iyi bir sınıflama performansı göstermektedir. Ancak BK-EYK tabanlı BİM sınıflayıcısı %98.61 ile en iyi sınıflama performansını göstermiştir.

6. SONUÇLAR

1. Bu tezde BK-EYK tabanlı BİM sınıflayıcısı adında yeni bir bulanık sınıflama algoritması önerilmiştir. Bu sınıflayıcı BK-EYK sınıflayıcısına yakın bir algoritmadır. Ancak, BK-EYK sınıflayıcısı bütün öznitelikleri alıp bir uzaklık (Euclid uzaklığı) ifadesi ile sınıfları temsil eder. BK-EYK tabanlı BİM sınıflayıcısı ise öznitelikleri teker teker değerlendirmektedir. Dolayısıyla özniteliklerin sınıfları kötü temsil etmedeki dezavantajı önlenmiş olur. Bu durum Tablo 5-4'den rahatlıkla gözlenebilir.
2. Önerdiğimiz BK-EYK tabanlı BİM Sınıflayıcısı kol kaslarından alınmış EMG işaretlerinin sınıflanmasında kullanılmış ve sınıflama performansı Keskin K-EYK, BEYÜ ve yapay sinir ağı (ANN) algoritmalarının performansları ile karşılaştırılmıştır. Tablo-6.1. de görüldüğü gibi BK-EYK tabanlı BİM sınıflayıcısı %98.61 doğru sınıflama ile en iyi sınıflama sonucunu vermiştir. BİM kullanılmayan BK-EYK sınıflayıcısı için sınıflama performansı K-EYK ile yakın değerlerdir. Bu karşılaştırma sonucunda önerdiğimiz sınıflayıcının en yüksek sınıflama performansına sahip olduğu görülmüştür.

Tablo-6.1) Algoritmalara Ait Doğru Sınıflama Sonuçları Yüzde Olarak Verilmiştir

			Bulanık İlişki Matrisi İle	
K	BK-EYK	K-EYK	BK-EYK	K-EYK
2	63.89	63.89	98.61	72.22
3	66.66	68.06	97.22	65.28
4	66.66	66.66	97.22	65.28
5	66.66	63.89	97.22	52.78
6	68.06	72.22	97.22	50.00

Tablo-6.2) Algoritmalara ait doğru sınıflama sonuçları (%) de olarak verilmiştir

BEYÜ	ANN(2x6x6)
81,25	63,88

3. Yapılan bu karşılaştırmalar sonucunda öznitelik olarak sadece ilk iki özniteliğin kullanılmasının yeterli olduğu gözlenmiştir. Önerdiğimiz sınıflayıcı (BK-EYK tabanlı BİM sınıflayıcısı) sonuçlarına göre diğer öznitelikler sınıfların karışmasına sebebiyet vermekte ve sınıflayıcıların performansını düşürmektedir.

Ayrıca bu durum yapay sinir ağı sınıflayıcısının sonuçlarından da gözlenmektedir.

4. Önerilen sınıflayıcının avantajı yüksek performansa sahip olmasıdır. Dezavantajları ise işlem zamanının uzun olması ve çok bellek gerektirmesidir. Bu mantıklı bir kazanç-kayıp ilişkisidir. Çünkü yüksek performans, öznelik bazında ayrıntıların kullanılması ile gerçekleşmiştir. Bu ise işlem ve bellek yükünü arttırmıştır.
5. Önerdiğimiz sınıflayıcıda bir ön işleme ihtiyaç duyulmamaktadır. Yapay sinir ağlarının uzun öğrenme süreci gözönüne alındığı takdirde EMG işaretleri için önerdiğimiz sınıflayıcının kullanılması daha uygun olacaktır. Yapay Sinir Ağları için daha değişik ağ yapıları ile sınıflama yapmak mümkündür. Ancak burada görüldüğü gibi bu kol hareketlerinden elde edilen EMG işaretleri için kompleks bir sınıflayıcı değil basit ve etkin bir sınıflayıcının üstünlüğü ortaya konulmuştur.

KAYNAKLAR

- [1] Ö. Kuyumcu, "Elektromiyografik İşaretlerin Değerlendirilmesi," Yüksek Lisans Tezi, İ.T.Ü., İstanbul, 1989.
- [2] H. Bandemer, S. Goodwald, *Fuzzy sets, fuzzy logic, fuzzy methods with applications*. Chichester : J. Wiley, USA, 1995
- [3] E. Yazgan, *Tıp Elektronikine Giriş*, Ders Notları, İstanbul: İ.T.Ü., 1994.
- [4] A.T. Bahill, *Bioengineering: Biomedical, Medical and Clinical Engineering*. s. 1-44, USA, 1981.
- [5] H.G. Webster, *Medical Instrumentation: Application and Design*. USA, 1978.
- [6] A.H. Kayran, *Sayısal İşaret İşleme*. İstanbul: İ.T.Ü., 1993.
- [7] A. Kohen, *Biomedical Signal Processin*, Boca Raton: CRC Press, 1986.
- [8] B. Karlık, "Çok Fonksiyonlu Protezler için Yapay Sinir Ağları Kullanılarak Miyoelektrik Kontrol," Doktora Tezi, Y.T.Ü, İstanbul, 1994. (s.11-16)
- [9] D. Graupe, *Time Series Analysis, Identification and Adaptive Filtering*. Florida: Kriger, 1984.
- [10] D. Graupe, J. Magnussen, A.A. Beex, "A Microprocessor System for Multifunctional Control of Upper-limb Prothesis via Myoelectric Signal Identification," IEEE Trans. Automatic Control, vol. AC-23, pp. 538-544, Aug.1978.
- [11] Orfanidis, J. Sophocles, *Optimum Signal Processing: An Introduction*. Printice-Hall, Newyork, 1988.
- [12] M. Körtrek, "Biyolojik İşaret İşleme," Ders Notları, İstanbul: İ.T.Ü., 1994.
- [13] A.H. Kayran, *Rastgele İşaretler ve İşaret İşlemedeki Uygulamaları*. İ.T.Ü., 1994.


- [14] M. Kortürek, *Tıp Elektronikinde Kullanılan Kuvvetlendiriciler ve Dönüştürücüler*. İ.T.Ü., 1988.
- [15] J. Salahi, "Identification and Recognition Applied to Biomedical Signals," Doktora Tezi, Illinois Inst. of Technology, USA, 1981.
- [16] D. Graupe, W.K. Cline, "Functional Separation of EMG Signals via ARMA Identification Methods for Prostheses Control Purposes," IEEE Trans. on Sys., Man and Cyb., Vol.SMC-5, pp.252-259, March. 1975.
- [17] A. Papoulis, *Probability, Random Variables, and Stochastic Processes*, 2nd ed. Singapore: McGraw-Hill, 1984.
- [18] G. Klir, T. Folger, *Fuzzy Sets, Uncertainty, and Information*. New Jersey, s.65-106 and 246-255, 1988.
- [19] A. Kandel, *Fuzzy Mathematical Techniques with Applications*. Addison-Wesley Publ. Company, s. 1-24, 1986.
- [20] T. Guo, B. Dubission, *Similarity of Classes and Fuzzy Clustering*. Fuzzy Sets and Systems, vol. 34, pp. 213-221, North Holland, 1990.
- [21] L.A. Zadeh, *Fuzzy Sets*. Information Control, Vol. 8 (1965), s.338-353.
- [22] H. Şeker, "Elektromiyografik İşaretlerin Bulanık Sınıflayıcılarla Sınıflandırılması", Yüksek Lisans Tezi, İ.T.Ü., İstanbul, 1995.
- [23] A. Gözel, H. Şeker, "Elektromiyografik (EMG) işaretlerin BK-EYK tabanlı BİM sınıflayıcısı yardımıyla değerlendirilmesi," SIU 99 Ankara, Bilkent s.99-103, 1999

ÖZGEÇMİŞ

1970 Çakırca/Balıkesir doğumluyum. İlk, orta ve lise öğrenimimi Konya'da tamamladım. 1995 yılında Selçuk Üniversitesi Elektronik Mühendisliği Bölümü'nden mezun oldum. Konya'da özel bir şirkette bir süre çalıştım. 1996 yılında Gebze Yüksek Teknoloji Enstitüsü'nde uzman olarak göreve başladım. Halen bu görevi sürdürmekteyim.



EK-1



```
function [m,i]=k_nn1
```

```
%***** DATA*****
```

```
%Giris Datasi (yani AR katsayilari)
```

```
p_p=[ -0.9680 -0.1540 0.1340 0.0740
```

```
-1.0490 0.0024 0.0410 0.1280
```

```
-0.9240 -0.1470 0.2690 -0.0770
```

```
-0.9450 -0.1330 0.0240 0.1330
```

```
-0.8690 -0.1640 0.0530 0.0860
```

```
-0.9970 -0.2150 0.3420 -0.0070
```

```
-0.8630 -0.2130 0.1270 0.0880
```

```
-0.7540 -0.2790 0.1480 0.1180
```

```
-0.9310 -0.2240 0.3030 -0.0780
```

```
-1.0010 -0.0950 0.0740 0.1460
```

```
-0.8820 -0.0020 -0.0130 0.1500
```

```
-0.9070 -0.1840 0.1060 0.0710
```

```
-1.6780 0.2650 0.6110 -0.1940
```

```
-1.6660 0.2910 0.5730 -0.1880
```

```
-1.7460 0.3650 0.6530 -0.2650
```

```
-1.3030 -0.1140 0.3290 0.1030
```

```
-1.6760 0.3870 0.3900 -0.0930
```

```
-1.6250 0.2350 0.6140 -0.2160
```

```
-1.5160 0.1850 0.3140 0.0246
```

```
-1.7620 0.3470 0.6950 -0.2710
```

```
-1.8000 0.4980 0.4920 -0.1860
```

```
-1.6310 0.2310 0.5420 -0.1330
```

```
-1.6570 0.2500 0.6240 -0.2010
```

```
-1.7240 0.3310 0.6220 -0.2210
```

```
-1.7630 0.3350 0.7790 -0.3380
```

```
-1.7140 0.3840 0.5340 -0.1910
```

```
-1.7840 0.4530 0.5940 -0.2550
```

```
-1.6970 0.4230 0.3590 -0.0750
```

```
-1.7920 0.4510 0.6380 -0.2880
```

```
-1.8890 0.5920 0.5950 -0.2910
```

```
-1.9140 0.6340 0.5800 -0.2940
```

```
-1.6210 0.2940 0.4370 -0.1010
```

```
-1.7480 0.4720 0.4840 -0.1910
```

```
-1.7410 0.3770 0.5840 -0.2090
```

```
-1.6000 0.1380 0.6470 -0.1830
```

```
-1.6460 0.2810 0.5030 0.1300
```

```
-1.7180 0.1790 0.8640 -0.3220
```

```
-2.1550 1.0720 0.4160 -0.3280
```

```
-2.1090 0.9500 0.5250 -0.3620
```

```
-1.9880 0.7150 0.6350 -0.3570
```

```
-2.0300 0.8740 0.3940 -0.2340
```

```
-2.0360 0.7270 0.7510 0.4380
```

```
-2.1160 0.9990 0.4430 -0.3220
```



```
-2.0150 0.8290 0.5130 -0.3200
-1.9380 0.6720 0.6050 -0.3300
-2.1950 1.1460 0.3780 -0.3270
-2.0140 0.7130 0.7020 -0.3970
-1.9620 0.6790 0.6100 -0.3230
-2.2910 1.4160 0.1560 -0.2760
-2.2230 1.1920 0.3780 -0.3440
-2.2800 2.1280 0.4800 -0.0850
-2.1850 1.1860 0.3550 -0.3040
-2.1330 1.0160 0.4880 -0.3680
-2.3200 1.3980 0.2490 0.3240
-2.2730 1.3090 0.3080 -0.3410
-2.1540 1.0940 0.3890 0.3240
-2.2180 1.1890 0.4090 -0.3760
-2.3500 1.5140 0.1340 -0.2840
-2.3100 1.4120 0.2050 -0.3040
-2.1000 0.9140 0.5130 -0.3370
-2.3540 1.4850 0.1450 -0.2740
-2.4720 1.8380 -0.2050 -0.1570
-2.4570 1.7530 -0.0860 -0.2070
-2.3920 1.6400 0.0100 -0.2450
-2.3730 1.5660 0.0360 -0.2270
-2.2370 1.2800 0.2700 -0.3130
-2.4540 1.7940 -0.1240 -0.2130
-2.6320 2.2900 -0.6120 -0.0460
-2.5100 1.9040 -0.2000 -0.1910
-2.3600 1.5450 0.0750 -0.2560
-2.5900 2.1400 -0.4390 -0.1100
-2.4750 1.8530 -0.2130 -0.1620];
```


```
%Cikis datasi
```

```
t_p=[
```

```
1 0 0 0 0 0
1 0 0 0 0 0
1 0 0 0 0 0
1 0 0 0 0 0
1 0 0 0 0 0
1 0 0 0 0 0
1 0 0 0 0 0
1 0 0 0 0 0
1 0 0 0 0 0
1 0 0 0 0 0
1 0 0 0 0 0
1 0 0 0 0 0
0 1 0 0 0 0
0 1 0 0 0 0
0 1 0 0 0 0
0 1 0 0 0 0
0 1 0 0 0 0
0 1 0 0 0 0
```

[illegible]

0	0	0	0	0	1
0	0	0	0	0	1
0	0	0	0	0	1
0	0	0	0	0	1



```

];
%*****
input=fopen('iris_inp.dat','r');
p_p=fscanf(input,'%f\n',[4,150]);
fclose(input);
p_p=p_p';

output=fopen('iris_outp.dat','r');
t_p=fscanf(output,'%f\n',[3,150]);
fclose(output);
t_p=t_p';

K=1; %K-Nearest Neighbour
mm=2; %degree of FUZZINESS
for K=1:149
K
%*****
t=t_p;
mem=t_p;
xl=p_p;
%*****
ln(2)=50;
ln(3)=100;
ln(4)=150;
ln(5)=132;
%*****

for tt=1:size(t,1)
%tt
xunl=p_p(tt,:);
%mem=t_p;
%xl=p_p;

%leave-one-out
%      for xx=1:size(xl,1)-1
%      if (tt==xx) xl_loo(xx,:)=xl(xx+1,:);
%      else xl_loo(xx,:)=xl(xx,:);end
%      for xx=tt+1:size(xl,1)-1

```

```

%         xl_loo(xx,:)=xl(xx+1,:);end
%     end

%     for xx=1:size(xl,1)-1
%         if (tt==xx) mem_loo(xx,:)=mem(xx+1,:);
%         else mem_loo(xx,:)=mem(xx,:);end
%         for xx=tt+1:size(xl,1)-1
%             mem_loo(xx,:)=mem(xx+1,:);end
%         end

%     xl=xl_loo;
%     mem=mem_loo;

```

```

%xl
%x=input('aaaaaaaaaaaaa')

```

```

%Euclidean Distance
%xl=labeled, xunl=unlabeled
for k=1:size(xl,1)
d(k)=0;
    for i=1:size(xl',1)
        d1=(xl(k,i)-xunl(1,i));
        d2=(xl(k,i)-xunl(1,i));
        d3=d1*d2;
        d(k)=d(k)+d3;
    end
end

```

```

%d'
dnew=d; %*****

```

```

%Order from min to max

```

```

for k=1:size(d',1)

    [m,i]=min(d');
%    [m,i]
    dnew(i)=(m+2000)*20;
    dminson(k)=m;

```

```

ive One Out *****
ze(dminson,1)-1
_loo(q,:)=dminson(q+1,:);

_min_max_loo;

ze(newmem,1)-1
:)=newmem(q+1,:);

```

```

k_nn_dist=0;
for i=1:K
mem1=mem1+(newmem(i,:)*((1/dminson(i))^(1/(mm-1)))));
mem2=mem2+newmem(i,:);
k_nn_dist=k_nn_dist+(newmem(i,:)*dminson(i));
end

```

```

mem1=mem1/dist;

```

```

%mem1

```

```

%mem2

```

```

mem2=mem2/K;

```

```

%mem2

```

```

%k_nn_dist

```

```

%x=input('stop for k_nn_dist')

```

```

%mem1 % Fuzzy K-NN

```

```

%mem2 % K-NN

```

```

[m1,i]=max(mem1);

```

```

[m2,j]=max(mem2);

```

```

[m3,kk]=max(k_nn_dist);

```

```

decision1(tt)=i;

```

```

decision2(tt)=j;

```

```

decision3(tt)=kk;

```

```

%[m1,i]

```

```

%[m2,j]

```

```

%decision1

```

```

%decision2

```

```

%x=input('dur-stop-look-bak')

```

```

end

```

```

decision1' %fuzzy k_nn

```

```

decision2' %k_nn

```

```

decision3' %k_nn_dist

```

```

%Recognition Table

```

```
%EMG DATASI
```

```
%*****
```

```
rec=decision1;
```

```
t=t;
```

```
for i=1:size(t,1)
```

```
    for j=1:size(t',1)
```

```
        if (t(i,j)==0.9) acc(i)=j;
```

```
        else t(i,j)=t(i,j);end
```

```
    end
```

```
end
```

```
cn=max(acc);
```

```
acc=acc';
```

```
%for i=2:cn+1
```

```
% ln(i)=input('Break Point of class 1,2,3,..cn');
```

```
%end
```

```
for i=1:cn
```

```
    for j=1:cn
```

```
        tr(i,j)=0;
```

```
    end
```

```
end
```

```
ln(1)=0;
```

```
for i=1:cn
```

```
    for k=ln(i)+1:ln(i+1)
```

```
        if (acc(k)-rec(k)==0) tr(i,i)=tr(i,i)+1;
```

```
        elseif (acc(k)-rec(k)==-1) tr(i,i+1)=tr(i,i+1)+1;
```

```
        elseif (acc(k)-rec(k)==-2) tr(i,i+2)=tr(i,i+2)+1;
```

```
        elseif (acc(k)-rec(k)==-3) tr(i,i+3)=tr(i,i+3)+1;
```

```
        elseif (acc(k)-rec(k)==1) tr(i,i-1)=tr(i,i-1)+1;
```

```
        elseif (acc(k)-rec(k)==2) tr(i,i-2)=tr(i,i-2)+1;
```

```
        else tr(i,i-3)=tr(i,i-3)+1;
```

```
    end
```

```
end
```

```
end
```

```

tr
x1(K)=trace(tr);
x1(K)

%*****
% *****
rec=decision2;
t=t;

for i=1:size(t,1)
    for j=1:size(t',1)
        if (t(i,j)==0.9) acc(i)=j;
        else t(i,j)=t(i,j);end
    end
end
cn=max(acc);
acc=acc';

%for i=2:cn+1
% ln(i)=input('Break Point of class 1,2,3,..cn');
%end

for i=1:cn
    for j=1:cn
        tr(i,j)=0;
    end
end

ln(1)=0;

for i=1:cn
    for k=ln(i)+1:ln(i+1)
        if (acc(k)-rec(k)==0) tr(i,i)=tr(i,i)+1;
        elseif (acc(k)-rec(k)==-1) tr(i,i+1)=tr(i,i+1)+1;
        elseif (acc(k)-rec(k)==-2) tr(i,i+2)=tr(i,i+2)+1;
        elseif (acc(k)-rec(k)==-3) tr(i,i+3)=tr(i,i+3)+1;

        elseif (acc(k)-rec(k)==1) tr(i,i-1)=tr(i,i-1)+1;
        elseif (acc(k)-rec(k)==2) tr(i,i-2)=tr(i,i-2)+1;
    end
end

```

```

        else
            tr(i,i-3)=tr(i,i-3)+1;
        end
    end
end
end

```

```

tr
x2(K)=trace(tr);
x2(K)

```

```

%*****
% *****
rec=decision3;
t=t;

```

```

for i=1:size(t,1)
    for j=1:size(t',1)
        if (t(i,j)==0.9) acc(i)=j;
        else t(i,j)=t(i,j);end
    end
end
cn=max(acc);
acc=acc';

```

```

%for i=2:cn+1
% ln(i)=input('Break Point of class 1,2,3,..cn');
%end

```

```

for i=1:cn
    for j=1:cn
        tr(i,j)=0;
    end
end
end

```

```

ln(1)=0;

```

```

for i=1:cn
    for k=ln(i)+1:ln(i+1)
        if (acc(k)-rec(k)==0) tr(i,i)=tr(i,i)+1;
        elseif (acc(k)-rec(k)==-1) tr(i,i+1)=tr(i,i+1)+1;

```

```
elseif (acc(k)-rec(k)==-2) tr(i,i+2)=tr(i,i+2)+1;
elseif (acc(k)-rec(k)==-3) tr(i,i+3)=tr(i,i+3)+1;

elseif (acc(k)-rec(k)==1) tr(i,i-1)=tr(i,i-1)+1;
elseif (acc(k)-rec(k)==2) tr(i,i-2)=tr(i,i-2)+1;
else
    tr(i,i-3)=tr(i,i-3)+1;
end
end
end

tr
x3(K)=trace(tr);
x3(K)

end

end

x1'
x2'
x3'

x1=x1';
x2=x2';
x3=x3';
k=1:149;
plot(k,x1',k,x2',k,x3')
```

EK-2

Elektromiyografik (EMG) İşaretlerin Bulanık K-En Yakın Komşuluk Tabanlı Bulanık İlişki Matrisi Yardımıyla Değerlendirilmesi

Alpaslan GÖZEL

Hüseyin ŞEKER

Gebze Yüksek Teknoloji Enstitüsü, Çayırova Kampüsü, Gebze / Kocaeli
Tel : 262 - 653 84 97 Fax : 262 - 653 84 90
gozel@penta.gyte.edu.tr

Özet :

Bu çalışmada yeni bir bulanık örüntü tanıma algoritması önerilmiştir. Bu önerilen algoritma ile EMG işaretini temsil eden her bir öznitelik ayrı ayrı dikkate alınmıştır. Altı değişik sınıftan oluşan EMG işaretlerinin öznitelikleri Öz-Bağımlı Model ile elde edilmiştir. Önerilen yeni metod, K-En Yakın Komşuluk Sınıflayıcısı, Bulanık K-En Yakın Komşuluk Sınıflayıcısı ve Yapay Sinir Ağı (Back Propagation Neural Network) Sınıflayıcısı ile karşılaştırılmıştır. Elde edilen sonuçlar, önerilen metodun üstünlüğünü ortaya koymaktadır.

Giriş :

K-En Yakın Komşuluk sınıflayıcısı en etkin sınıflama algoritmalarından birisidir. Herhangi bir on kabule gerek duymayan ve on işlemlere gerek kalmadan etiketlenmemiş bir örüntüyü sınıflamak için kullanılır. Sınıflama performansı, seçilen komşuluk sayısı ile değişebilmektedir. Burada, uzaklık olarak en yakın K değer alınır ve bu K tane örüntünün sınıflarından hangisi fazla ise etiketlenmemiş örüntü o sınıfa atanır. Bulanık K-En Yakın Komşuluk Sınıflayıcısı'nda ise bunların üyelik değerlerine bakılır ve hangi üyelik değeri yüksek ise örüntü o sınıfa atanır[1]. Ancak, bu algoritmalarda bütün öznitelik değerlerin bir kombinasyonu olan Euclidean Uzaklığı bulunur. Fakat, her öznitelik farklı düzeyde örüntünün tanınmasını kolaylaştırabilir ve/veya zorlaştırabilir. Bu çalışmada her bir özniteliği ayrı ayrı ele alan Bulanık K-En Yakın Komşuluk Tabanlı Bulanık İlişki Matrisi önerilmiştir. Bu algoritma için Bulanık K-En Yakın Komşuluk sınıflama algoritması her bir öznitelik için ayrı ayrı islenir. Her bir sınıf ve her bir öznitelik için elde edilen üyelik değerleri bir matris olarak ele alınır ve bu matrise Bulanık İlişki Matrisi adı verilir. Bu çalışmada önerilen yöntem Elektromiyografik (EMG) İşaretlerin sınıflanması için kullanılmıştır.



Bulanık K-En Yakın Komşuluk Tabanlı Bulanık İlişki Matrisi :

Bu algoritma, Bulanık K- En Yakın Komşuluk algoritması ile işleyiş olarak aynıdır. Ancak, tek farkı Bulanık K- En Yakın Komşuluk algoritması, bu algorithmada her bir öznitelik için ayrı ayrı gerçekleştirilmektedir. Burada da yine Euclidean uzaklığı kullanılmaktadır. Dolayısı ile her bir öz niteliğin her bir sınıf için bir üyeliği hesaplanmaktadır. Böylece satırları sınıfları, sütunları da öz nitelikleri gösteren bir matris oluşmaktadır. Bu matrise de Bulanık İlişki Matrisi (Fuzzy Relation Matrix - FRM) adi verilmektedir.

$i=1,2,3,...,C$ (C =Sınıf Sayısı) ve $j=1,2,3,...,N$ (N =Öznitelik Sayısı) olmak üzere Bulanık K- En Yakın Komşuluk Tabanlı Bulanık İlişki Matrisi aşağıdaki gibi tanımlanabilir:

$$R_F = \begin{matrix} & \begin{matrix} U_{11} & \dots & U_{1j} & \dots & U_{1N} \end{matrix} \\ \begin{matrix} \dots & \dots & \dots & \dots & \dots \end{matrix} \\ U_{i1} & \dots & U_{ij} & \dots & U_{iN} \\ \begin{matrix} \dots & \dots & \dots & \dots & \dots \end{matrix} \\ U_{C1} & \dots & U_{Cj} & \dots & U_{CN} \end{matrix}$$


Bu matriste U_{ij} , (j) . inci öz niteliğin (i) .inci sınıfa olan üyelik derecesini göstermektedir. Tabiidir ki bu değerler 0 ile 1 arasındadır.

Bir işaret, öz niteliklerinin hesap edilip bu matrisin elemanlarının hesap edilmesinden sonra bu işaretin hangi sınıfa ait olduğunun tespit edilmesi için aşağıdaki adımlar takip edilir:

- 1- R_F matrisinin her bir satırında MAX (Maksimum) işlemi yaparak her bir sınıf için o sınıfı temsil eden üyelik derecesi bulunur. (Her bir satir için o satirdaki en büyük değer alınır).
- 2- (1). adim sonucunda R_F matrisi tek sütunlu ve C satirli bir matris haline gelir. Bu matris üzerinde tekrar MAX işlemi yapılarak hangi satırda en büyük değer elde ediliyorsa işaret o sınıfa atanır.

EMG işaretlerinin sınıflanmasında bu matris 6×4 boyutludur. (Sınıf Sayısı= $C=6$, Öz nitelik Sayısı= $N=4$).

FRM'nin oluşturulması daha önceden belirlenen üyelik fonksiyonlarından elde edilecek değerlerin hesaplanması ile elde edilmekteydi. Bu üyelik fonksiyonları ya eldeki mevcut veriler göz önüne alınarak bulunmakta ya da bu konuda uzman kişilerin yardımı ile elde edilmekteydi [2]. Bu her iki durumda bir on çalışmayı gerektirmekte ve hata payını yükseltmektedir. Bu çalışma ile hiçbir on isleme gerek kalmamaktadır ve hiçbir varsayım yapılmamaktadır.



Elektromiyografik (EMG) İşaretlerin İşlenmesi ve Öznitelik Çıkarımı :

EMG işaretleri kol kaslarından altı değişik hareket yapılarak alınmıştır. Bu işaretler 300 msn de durağan varsayılarak Öz-Bağlanımlı model ile modellenmiştir. Model derecesi 4 seçilmiştir. Yani kullanılan öznitelik sayısı 4 olarak alınmıştır. Herbir sınıf için 12 değişik kayıt alınmıştır. Dolayısı ile toplam 72 kayıt elde edilmiştir[3].

Sonuçlar :

Sınıflama işlemi **Leave-One-Out** yöntemi kullanılarak gerçekleştirilmiştir. Bu yöntemde sınıflanması istenilen işaret, öğrenme kümesinin dışında bırakılmıştır. Elimizde 72 data olduğuna göre bu yöntemde sınıflanması düşünülen data öğrenme kümesinin dışında bırakılmış dolayısı ile öğrenme kümesinde 71 data kalmıştır.

Yapay Sinir Agi ile yapılan çalışmada Back-Propagation Neural Network kullanılmıştır. Bu ağda tek saklı katman kullanılmış ve saklı katmandaki neuron sayısı da 6 seçilmiştir. Ağ sadece 5000 adım koşturulmuştur. Sonuçta elde edilen sınıflama oranı % 61.111 olarak elde edilmiştir.

K-En Yakın Komşuluk ve Bulanık K-En Yakın Komşuluk sınıflayıcıları için sonuçlar Tablo-1 de sol tarafta gösterilmiştir. İlişki Matrisi kullanılarak yapılan K-En Yakın Komşuluk ve Bulanık K-En Yakın Komşuluk sınıflama algoritmalarından elde edilen sonuçlar da Tablo-1 de sağ tarafta gösterilmiştir. Bu metodlarda değişik Komşuluk değerleri (K) için sonuçlar alınmıştır.

Sonuçlardan önerilen “Bulanık K-En Yakın Komşuluk Tabanlı Bulanık İlişki Matrisi” örüntü tanıma yönteminin üstünlüğü gözlenmektedir.

Tablo-1) Aşağıda Algoritmalara Ait Doğru Sınıflama Sonuçları Yüzde Olarak Verilmiştir.

Komşuluk Sayısı = K	Bulanık İlişki Matrisi İle			
	Bulanık K-En Yakın Komşuluk	K-En Yakın Komşuluk	Bulanık K-En Yakın Komşuluk	K-En Yakın Komşuluk
2	63.89	63.89	98.61	72.22
3	66.66	68.06	97.22	65.28
4	66.66	66.66	97.22	65.28
5	66.66	63.89	97.22	52.78
6	68.06	72.22	97.22	50.00

Kaynaklar :

- [1]D. Cabello, S. Barro, “Fuzzy K-Nearest Neighbour Classifiers for Ventricular Arrhythmia Detection”, Int. Journal of Biomedical Computing, sayfa:77-93, 1991.
- [2]G. Klir, T.Folger. “Fuzzy Sets, Uncertainty, and Information”, New Jersey, 1988.



[3]H. Şeker, "Elektromiyografik İşaretlerin Bulanık Sınıflayıcılarla Sınıflandırılması", Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, 1995.

