



İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

~~İSTANBUL ÜNİVERSİTESİ~~

130794

YÜKSEK LİSANS TEZİ

**BULANIK-YAPAY SİNİR AĞLARI İLE BİYOMEDİKAL
GÖRÜNTÜ İŞLENMESİ**

ABDURRAHİM AKGÜNDOĞDU

Biyomedikal Mühendisliği Anabilim Dalı

Danışman

Doç. Dr. Osman Nuri UÇAN

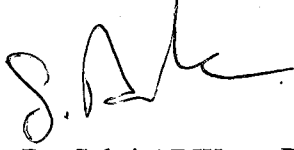
Haziran 2003

İSTANBUL

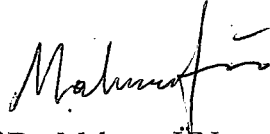
Osman Nuri Uçan
Abdurrahim Akgündoğdu

İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bu çalışma 15/07/2003 tarihinde aşağıdaki jüri tarafından Biyomedikal Mühendisliği Anabilim Dalı Biyomedikal Mühendisliği programında Yüksek Lisans Tezi olarak kabul edilmiştir.



Doç.Dr. Sabri ARIK



Prof.Dr. Mahmut ÜN



Doç.Dr. Osman Nuri UÇAN
(Danışman)



Doç.Dr. Serhat ŞEKER



Doç.Dr. Sedef KENT

ÖNSÖZ

Bu tezde, Lisans ve Yüksek Lisans öğrenimim boyunca ilgimi çeken yapay sinir ağları, bulanık mantık gibi konuların birlikte modellenmesiyle oluşturulan “Bulanık-Yapay Sinir Ağları” konusunu , görüntü işleme teknikleriyle birlikte ele aldım.

Bu tezin hazırlanmasında , tez danışmanlığımı yapan sayın Doç.Dr. Osman Nuri UÇAN 'a , yardımlarından dolayı İstanbul Üniversitesi Elektronik Mühendisliği bölümünde halen öğrenim gören sayın Etkin ELVER'e, İstanbul Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü Araştırma Görevlisi sayın Mesut ÇEVİK'e ve her aşamadaki manevi desteklerinden dolayı aileme teşekkürlerimi sunarım.

Abdurrahim AKGÜNDOĞDU

HAZİRAN 2003

İÇİNDEKİLER

	SAYFA NO
ÖNSÖZ	I
İÇİNDEKİLER	II
ŞEKİL LİSTESİ	VI
TABLO LİSTESİ	VIII
ÖZET	IX
SUMMARY	XI
1. GİRİŞ	1
2. MALZEMELER VE YÖNTEM	3
2.1. GÖRÜNTÜ İŞLEME TEMELLERİ	3
2.1.1. SAYISAL GÖRÜNTÜ TANIMLAMALARI	4
2.1.2. SIK KULLANILAN DEĞERLER	5
2.1.3. GÖRÜNTÜ İŞLEMLERİNİN KARAKTERİSTİKLERİ	6
2.1.3.1. İŞLEM TİPLERİ	6
2.1.3.2. KOMŞULUK TİPLERİ	7
2.1.4. VİDEO PARAMETRELERİ	8
2.1.5. ARAÇLAR	9
2.1.5.1. KONVÜLÜSYON	9
2.1.5.1.1. KONVÜLÜSYON ÖZELLİKLERİ	9
2.1.5.2. FOURIER TRANSFORMLARI	10
2.1.5.2.1. FOURIER TRANSFORM ÖZELLİKLERİ	11
2.1.5.2.1.1. FAZ VE BÜYÜKLÜĞÜN ÖNEMİ	13
2.1.5.2.1.2. DAİRESEL SİMETRİK SİNYALLER	14
2.1.5.3. DIŞ HAT (KONTUR) GÖSTERİMİ	15
2.1.5.3.1. ZİNCİR KOD	15
2.1.5.3.2. ZİNCİR KOD ÖZELLİKLERİ	16
2.1.5.3.3. CRACK KOD	16
2.1.6. GÜRÜLTÜ (NOISE)	17
2.1.6.1. FOTON GÜRÜLTÜSÜ	17
2.1.6.2. İSİSAL GÜRÜLTÜ	18

2.1.6.3. CHİP ÜSTÜNDEKİ ELEKTRON GÜRÜLTÜSÜ	18
2.1.6.4. KTC NOISE	19
2.2. YAPAY SİNİR AĞLARI	20
2.2.1. BİYOLOJİK NÖRON YAPISI	21
2.2.2. AKTİVASYON FONKSİYONLARI	24
2.2.3. İŞLEMCİ ELEMAN (YAPAY NÖRON)	26
2.2.4. YSA İLE HESAPLAMANNIN ÖZELLİKLERİ	27
2.2.4.1. DOĞRUSAL OLMAMA	27
2.2.4.2. ÖĞRENME	27
2.2.4.3. GENELLEME	27
2.2.4.4. UYARLANABİLİRLİK	28
2.2.4.5. DAĞITILMIŞ BİRLEŞİK HAFIZA	28
2.2.4.6. HATA TOLERANSI	28
2.2.4.7. PARALEL İŞLEM YAPMA	28
2.2.5. YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI	29
2.2.5.1. YSA'LARIN YAPILARINA GÖRE SINIFLANDIRILMASI	29
2.2.5.1.1. İLERİ BESLEMELİ AĞLAR	29
2.2.5.1.2. GERİ BESLEMELİ AĞLAR	30
2.2.6.1. YSA'LARIN ÖĞRENME ALG. GÖRE SINIFLANDIRILMASI	30
2.2.6.1.1. DANIŞMANLI ÖĞRENME (SUPERVISED LEARNING)	31
2.2.6.1.2. DANIŞMANSIZ ÖĞRENME (UNSUPERVISED LEARNING)	31
2.2.6.1.3. TAKVİYELİ ÖĞRENME (REINFORCEMENT LEARNING)	32
2.2.7. ÇOK KATMANLI PERSEPTRONLAR (MLP) VE ÖĞRENME ALG.	33
2.2.7.1. ÇOK KATMANLI PERSEPTRONLAR	33
2.2.7.2. GERİ YAYILIM ALGORİTMASI	34
2.2.7.3. DELTA-BAR-DELTA KURALI	36
2.2.7.4. GENİŞLETİLMİŞ DELTA-BAR-DELTA (EXTENDED DBD)	38
2.2.7.5. HIZLI YAYILIM (QUICKPROP)	41
2.2.8. DİĞER YAPAY SİNİR AĞLARI	44
2.2.8.1. LVQ (LEARNING VECTOR QUANTIZATION)	44
2.2.8.2. HOPFIELD AĞI	46
2.2.8.3. ELMAN VE JORDAN AĞLARI	47
2.2.8.4. KOHONEN AĞI	49

2.2.8.5. ART (ADAPTIVE RESONANCE THEORY) AĞI	50
2.2.9. YSA'NIN MÜHENDİSLİK UYGULAMALARI	51
2.3. BULANIK MANTIK	54
2.3.1. BULANIK MANTIK KAVRAMI	54
2.3.2. BULANIK KÜMELER	56
2.3.2.1. TEMEL KAVRAMLAR	56
2.3.2.2. BULANIK SAYILAR	61
2.3.2.3. BULANIK KÜME İŞLEMLERİ	65
2.3.3. T-NORM VE T-KONORM OPERATÖRLERİ	67
2.3.3.1. TANIM: T-NORM	67
2.3.3.2. TANIM: T-KONORM (S_NORM)	68
2.3.3.3. TEOREM: GENELLEŞTİRİLMİŞ DEMORGAN KURALLARI	69
2.3.4. BULANIK EĞER - ÖYLEYSE KURALLARI	69
2.3.5. DURULAŞTIRMA YÖNTEMLERİ	70
2.3.5.1. AĞIRLIK MERKEZİ METODU	71
2.3.5.2. EŞİT ALAN METODU	71
2.3.5.3. EN KÜÇÜK MAKSİMUM METODU	71
2.3.5.4. EN BÜYÜK MAKSİMUM METODU	72
2.3.5.5. MAKSİMUMLARIN ORTALAMASI METODU	72
2.3.6. BULANIK KIYASLAMA VE SUGENO YAKLAŞIMI	72
2.4. BULANIK-YAPAY SİNİR AĞLARI	74
2.4.1. BYSA YAPISI	75
2.5. ESWL AYGITI VE GENEL BİLGİLER	82
2.5.1. ESWL NEDİR ?	83
2.5.2 KIRILIM TEORİLERİ	83
2.5.3. YESD KAYNAKLARI	84
2.5.3.1. ELEKTROMANYETİK KAYNAK	84
2.5.3.2. PIEZOELEKTRİK KAYNAK	84
2.5.3.3. ELEKTROHİDROLİK KAYNAK (EHK)	85
2.5.4. TAŞ KIRILIM TEORİLERİ	86
2.5.4.1. KIRILGANLIK	87
2.5.4.2. TAŞIN CİNSİ VE KIRILGANLIK	88
2.5.4.3. TAŞIN YERLEŞİMİ VE KIRILGANLIK	88

2.5.4.4. TAŞIN BÜYÜKLÜĞÜ VE KIRILGANLIK	88
2.5.4.5. TAŞTAN TEMİZLENME (TT)	88
2.5.4.6. TAŞIN TEKRARLAMASI	89
2.5.4.7. KOMPLİKASYONLAR	89
2.5.4.8. ESWL NİN DOKU ETKİSİ	89
2.5.4.9. KESİN KONTRENDİKASYON	90
2.5.4.10. KISMI KONTRENDİKASYON	90
2.5.5. TAŞ KIRMA YÖNTEMİNİN DİĞER KULLANIM ALANLARI	90
3. BULGULAR	92
3.1. ESWL AYGITININ BYSA İLE DENETİMİ	92
3.2. YÖNTEM	94
3.3. GÖRÜNTÜ İŞLEME	94
3.4. BULANIK YAPAY SİNİR AĞI UYGULAMASI	97
4. TARTIŞMA VE SONUÇLAR	103
5. KAYNAKLAR	104
6. ÖZGEÇMİŞ	107

ŞEKİL LİSTESİ

SAYFA NO

Şekil 2.1.1 Sürekli görüntünün sayısallaştırılması	4
Şekil 2.1.2 Görüntü işlemlerinin çeşitli tiplerinin resimsel örneği	6
Şekil 2.1.3 Dikdörtgen ve Altıgen biçimli örneklemeler.	7
Şekil 2.1.4 Fourier transformu çıktıları	13
Şekil 2.1.5 Görüntünün yeniden büyüklük ve faz bilgisi üzerine düzenlenmesi.	14
Şekil 2.1.6 Gölge bölge	16
Şekil 2.1.7 Crack kodlara ilişkin şekiller.	17
Şekil 2.2.1 Biyolojik sinir sisteminin blok gösterimi.	22
Şekil 2.2.2 Nöron Modeli	24
Şekil 2.2.3 YSA’larda en çok tercih edilen aktivasyon fonksiyonları	25
Şekil 2.2.4 Bir işlemci elemanı (yapay nöron).	26
Şekil 2.2.5 İleri beslemeli ağ için blok diyagram	29
Şekil 2.2.6 Geri beslemeli ağ için blok diyagram	30
Şekil 2.2.7 Danışmanlı öğrenme yapısı.	31
Şekil 2.2.8 Danışmansız öğrenme yapısı.	32
Şekil 2.2.9 Takviyeli öğrenme yapısı.	32
Şekil 2.2.10 Geri yayılım MLP yapısı.	34
Şekil 2.2.11 Çok katmanlı bir perseptron geri yayılım akış şeması	36
Şekil 2.2.14 LVQ ağı	45
Şekil 2.2.15 Hopfield ağı	47
Şekil 2.2.16 Elman ve Jordan ağları	48
Şekil 2.2.17 Kohonen ağı	50
Şekil 2.2.18 ART-1 ağı	51
Şekil 2.3.1 Yaşlara ait üyelik fonksiyonu	55
Şekil 2.3.2. 1’e yaklaşan sayıların üyelik fonksiyonu	57
Şekil 2.3.3 Bir sabit diskin dönme hızını belirten μ bulanık kümesi	59
Şekil 2.3.4 Genç, orta yaşlı ve yaşlı kavramlarını temsil eden üyelik fonks.	60
Şekil 2.3.5 Üçgen bulanık sayı (triangular fuzzy number)	62
Şekil 2.3.6 Yamuk bulanık sayı	62
Şekil 2.3.7 A, B’nin alt-kümesi.	63

Şekil 2.3.8 Bazı Üyelik fonksiyonları	64
Şekil 2.3.9 A ve B üçgen bulanık sayılarının birleşimi	65
Şekil 2.3.10 A ve B üçgen bulanık sayılarının kesişimi, μ Üyelik fonksiyonu.	66
Şekil 2.3.11 A bulanık kümesinin tümleyeni	66
Şekil 2.3.12 Bulanık değerlerden elde edilecek duru değerler.	71
Şekil 2.3.13 Sugeno yaklaşımına ait örnekle ilgili grafikler.	73
Şekil 2.4.1 iki kurallı , iki girişli birinci dereceden sugeno bulanık modeli	76
Şekil 2.4.2 BYSA yapısı	76
Şekil 2.4.3 MLP ve BYSA için RMSE eğrileri	79
Şekil 2.4.4 Eğitim verisi	80
Şekil 2.4.5 Üyelik fonksiyonlarının başlangıç ve sonuçtaki durumu	81
Şekil 2.5.1 Elektro Manyetik Kaynakla YESD elde edilmesi	84
Şekil 2.5.2 Piezo Elektrik kaynakla YESD elde edilmesi	85
Şekil 2.5.3 Elektro Hidrolik Kaynakla YESD elde edilmesi	85
Şekil 2.5.4 Yek'in oluşumu	86
Şekil 2.5.5 Şok Dalgası ve Normal ses dalgası	87
Şekil 3.1.1 ESWL Aygıtı	93
Şekil 3.1.2 Böbrek taşı resimleri	95
Şekil 3.1.3 Solda böbrek taşı ve sağda kırılmaya başlamış böbrek taşı	96
Şekil 3.1.4 Seans boyunca yapılan toplam atım sayısının zamana göre değişimi	97
Şekil 3.1.5 X-ışını görüntülerindeki kenar noktaları sayısının zamana bağlı değ.	98
Şekil 3.1.6 Atım frekansının zamana göre değişimi	98
Şekil 3.1.7 Simülasyon Modeli	99
Şekil 3.1.8 Toplam kenar noktası sayısı girişleri için 10 üyelik fonks. bölgesi	99
Şekil 3.1.9 Toplam atım sayısı girişleri için 10 üyelik fonks. girişlerinin bölgesi	99
Şekil 3.1.10 Üyelik fonksiyonlarına göre örnek kuralların aldıkları değerler	100
Şekil 3.1.11 Giriş-Çıkış ilişkilerine göre, bulanık mantık sisteminin değer yüzeyi	101
Şekil 3.1.12 ESWL hata miktarı.	102

TABLO LİSTESİ

SAYFA NO

Tablo 2.1.1 Sayısal görüntü parametrelerinin yaygın değerleri	5
Tablo 2.1.2 Görüntü işlem tipleri.	6
Tablo 2.1.3 Standart video parametreleri	8
Tablo 2.2.1 Sınır sistemi ile YSA'nın benzerlikleri.	23



ÖZET

Bulanık-Yapay Sinir Ağlarıyla Biyomedikal Görüntü İşleme

Bu tez çalışmasıyla Bulanık Yapay Sinir Ağları'nın (BYSA) biyomedikal görüntü verilerini değerlendirmekte yararlı bir araç olduğu gösterilmeye çalışılmıştır. Yapay sinir ağlarının başarılı bir eğitilebilir sınıflandırıcı olarak kabul görmesi ve bulanık mantık sistemlerinin otomatik kontrol proseslerinde geleneksel kontrol sistemlerine göre ve ikili mantık sistemlerine göre daha anlaşılır modellerle çalışması zamanla her iki sistemin bütünleştirilmesi fikrini doğurmuştur.

BYSA verimli bir birleşik sistem olarak tıbbi görüntüleri değerlendirmek için kullanıldığında önemli yararlar sağlayacaktır. Bu tez çalışması kapsamında vücut dışından böbrek taşı kırılması işleminde kullanılan tıbbi bir aygıtın kontrolünün, röntgen görüntülerinin BYSA'lar ile yorumlanması sonucu daha başarılı olarak gerçekleştirilebileceği, uygulama olarak çalışılmıştır.

İlk bölümde konu genel anlamda kısaca tarif edilmeye çalışılmıştır.

İkinci bölüm olan Malzemeler ve Yöntem bölümü beş alt bölüm altında incelenmiştir.

Birinci bölümde görüntü işleme teorisinin yapıtaşlarını oluşturan temel yaklaşımlar incelenmiştir. Sinyalleri zaman serileri olarak inceleyen yaygın sinyal işleme yöntemlerinden türetilmiş olarak iki boyutlu görüntü sinyallerinin analizi anlatılmıştır.

İkinci bölümde yapay sinir ağlarına değinilmiştir. Yapay sinir ağları kapsam olarak geniş bir konudur ancak yapay sinir ağlarının temelleri oldukça anlaşılabilir olan birkaç kuralla belirlenir. Çeşitli yapay sinir ağı topolojilerine ve yapay sinir ağlarının eğitim yöntemlerine bu bölümde değinilmiştir.

Üçüncü bölümde geleneksel bulanık mantık sistemleri anlatılır. Bulanık mantık sisteminin bileşenleri olan üyelik fonksiyonları ve kurallar tarif edilir. Uygulamalarına kısaca değinilmiştir.

Dördüncü bölüm yapay sinir ağlarıyla bulanık mantık sisteminin başarılı bir birleşimi olan BYSA'ların yapısına detaylıca değinir. Tezde kullanılan BYSA modelinin matematiksel tarifi bu bölümde yapılmıştır.

Beşinci bölümde, ESWL (Extracorporeal Shock Wave Lithotripsy) aygıtı hakkında bilgi verilmiştir.

Üçüncü Bölüm uygulama bölümüdür. Çalışma konusu olarak seçilmiş böbrek taşı kırma işlemine bu bölümde değinilir. Öncelikle uygulamada kullanılan görüntü işleme yaklaşımına değinilmiştir. Daha sonra bir BYSA oluşturulmuştur. Daha sonra çeşitli örnek görüntü verilerini işleyerek bulanık mantık sisteminin aldığı değerler tarif edilir. Yapılan denemelerde başarılı sonuçlar elde edilmiştir. Bu sonuçlar çeşitli grafiklerle açıklanmaktadır.

SUMMARY

Biomedical Image Processing With Neuro-Fuzzy

In this thesis study it is proposed that the Adaptive Neuro Fuzzy Inference Systems (ANFIS) are useful tools in biomedical image processing applications. The widespread acceptance of Neural Networks as successful trainable classifiers and renown of Fuzzy Inference Systems (FIS) applications in system control, wherever it is preferred to binary logic and ordinary control theory, made its way to the integration of both systems as a new mathematical phenomenon.

The ANFIS as a successful integration will provide valuable benefits in biomedical image processing. In the content of this thesis study, it is experienced that the control of an Extracorporeal Shock Wave Lithotripsy (ESWL), a device used in kidney stone crushing operations, will be better successful with an ANFIS system that have input values obtained from some evaluations on x-ray images.

The first part is a brief introduction to the subject

The second part is studied five section.

The first part involves with the building stones of image processing theory. The analysis methods derived from the approach considering signals one dimensional time series. The evaluations of images as two dimensional signals are described.

Second part covers neural networks. Neural networks is a large subject but still have a basic and easy understandable constructions. Different network topologies and training algorithms are mentioned in this part.

Third part describes traditional fuzzy logic systems. The components of fuzzy logic systems such as membership functions and rules are introduced. Its applications are subjected.

Fourth part is a detailed description of ANFIS. The description of mathematical models for ANFIS systems used in this thesis is made.

Fifth part describes information about ESWL device.

Third part is the implementation part. As precedence the image processing approach in the project is described. After this an ANFIS is created, followed by a training section with the input values obtained from x-ray images. Experiments gave successful results and this results are represented within figures of graphs.



1. GİRİŞ

Günümüzde, ucuzlayan bilgi işlem maliyetleri yapay zeka becerilerine sahip aygıtların yaygınlaşmasına önayak olmuştur. Yüksek işlem gücü gerektiren görüntü işleme yöntemleri ve eğitilebilir sınıflandırma araçları uygulamaları artık günlük hayatta, endüstriyel aygıtlarda, tıbbi aygıtlarda ve tüketici elektroniğinde yerini almıştır.

Her alanda olduğu gibi tıp elektroniğinde de gelişmiş sinyal işleme teknikleri ile büyük miktardaki verinin hızlı bir şekilde işlenebilmesi önemli yararlar sağlar. Bu tez çalışmasında böbrek taşı kırma işlemi boyunca hastadan elde edilen x-ışını görüntülerinin görüntü işleme teknikleriyle arılaştırıldıktan sonra başarılı bir eğitilebilir sınıflandırma aracı olan Bulanık Yapay Sinir Ağları'nda (BYSA) kullanılması değerlendirilmiştir.

Geleneksel böbrek taşı kırma işleminde, yüksek enerjili akustik dalgalarla taş kırma işlemi boyunca, operasyonu yürüten uzman sürekli x-ışını görüntülerini yorumlar. Kırma işleminde böbrek taşı kendiliğinden idrara çıkma ile atılabilecek büyüklüğe ulaştığında operasyona son verilir. Ancak tüm tıbbi tedavi uygulamalarında olduğu gibi bu uygulamada da bir takım kısıtlamalar söz konusudur. Uygulanacak şok dalgalarının sıklığı yavaştan başlayarak taş kırma işleminin performansına göre zamanla artırılır. Artan sıklık değerleri için belli bir üst sınır vardır. Diğer yandan bu darbeler bir tedavi seansı boyunca belirli bir sayıyı geçmemelidir. Bu sayılar kullanılan aygıtın türüne göre FDA (Amerikan, Federal İlaç Kurumu) tarafından belirlenmiştir. Tüm bu operasyon uzmanlık gerektiren bir süreçtir, ürolog hekimler tarafından uygulanır.

Tez çalışmasında öne sürülen tekniklerle böbrek taşı kırma işleminde operatöre belirli ölçüde kılavuzluk edilebilir. Öncelikle yapılması gereken x-ışını görüntülerinin yorumlanmasıdır. Taşın kırılma işlemi boyunca x-ışını görüntülerinde çeşitli değişimler algılanır. Taş kırıldıkça o bölgeden geçen x-ışını miktarı artar. Artan x-ışını

görüntü yoğunlaştırıcının yüzey plakasını daha fazla pozlar ve görüntüde gözün algılayabileceği ölçüde parlaklık azalması olur. Bu azalma işaret işleme diliyle enerjinin azalması anlamına gelir. Dolayısıyla taş kırıldıkça taşın olduğu resim bölgesinde görüntü enerjisinin azalacağını söylemek yanlış olmaz. Diğer yandan taşın parçalara bölünmesi ilgili bölgeye uygulanacak bir kenar bulma algoritmasıyla da gözlenebilir. Taşın kırıldığı bölgelerde kontrast değişimi artacaktır. Röntgen görüntüleri keskin kenarlara sahip olmadığından yumuşak bir eşik değeri seçilirse taş kırıldıkça, kenar olarak işaretlenen noktaların sayısının arttığı gözlenebilir. Bu da x-ışını görüntülerini yorumlamak için bir diğer araçtır.

Yapay sinir ağları bir çok çeşidiyle eğitilebilir sınıflandırıcılar içinde, istatistik yöntemlerin yanında kendine önemli bir yer edinmiştir. Çeşitli katman sayısı ve nöron sayısındaki ve farklı aktivasyon fonksiyonlarına sahip yapay sinir ağları bir çok uygulamada başarıyla kullanılmıştır. Diğer yandan bulanık mantık yaklaşımı ise geleneksel kontrol sistemlerinden farklı olarak keskin karar mekanizmalarının önerilemediği durumlarda oldukça yaygındır. Her iki sistemin birleştirilmesi fikrinden doğan Bulanık Yapay Sinir Ağları, bulanık mantık sistemlerinin giriş çıkış eğitim çiftlerinden oluşan öğrenme verileriyle oluşturulabilmesini sağlar. Diğer yandan bulanık mantık sistemlerinde gelenekselleşen bazı topolojiler ve üyelik fonksiyonlarıyla BYSA'lar, alışlagelmiş yapay sinir ağları gibi çok katmanlı perseptron modellerinden daha yüksek performans gösterirler.

Bu tez çalışmasında görüntü işleme aşamasından sonra elde edilen veriler BYSA'ların eğitim çiftlerinde kullanılır. BYSA'ya giriş olarak verilen bir diğer değer o ana kadar yapılan şok atımı sayısıdır. Çıkışta beklenen değer ise uzmanın seçmeyi uygun gördüğü atım frekanslarıdır. Bu verilerle eğitilen BYSA artık farklı hastaların operasyonunda kullanılabilir. Kuşkusuz bu aşamada tüm denetimi BYSA'ya bırakmak doğru olmaz ancak BYSA kullanan bir yazılım tedavi aygıtının yazılımıyla birlikte kullanıldığında operatöre operasyon konusunda fikir verecektir. Ayrıca bu şekilde taşın kırılma miktarı da belirli bir metrik ile ifade edilebilir hale gelir. Ayrıca ne tür taşların nasıl bir işlem sonucunda ne kadar sürede kırılacağı konusunda bir veri tabanı oluşturulmasında kullanılabilir. Yapılan simülasyon sonuçları başarılı değerler üretmiştir.

2. MALZEMELER VE YÖNTEM

2.1. GÖRÜNTÜ İŞLEME TEMELLERİ

Modern sayısal teknoloji, basit sayısal devrelerden geliştirilmiş paralel bilgisayarlara kadar olan sistemler ile çok boyutlu sinyalleri işlemeyi mümkün kılan bir yapıda tasarlanmıştır. Bu işlemi üç sınıfa ayırabiliriz.

- Görüntü işleme görüntü girişi – görüntü çıkışı
- Görüntü analizi görüntü girişi – ölçüm çıkışı
- Görüntü anlama görüntü girişi – yüksek seviyeli tanımlama çıkışı

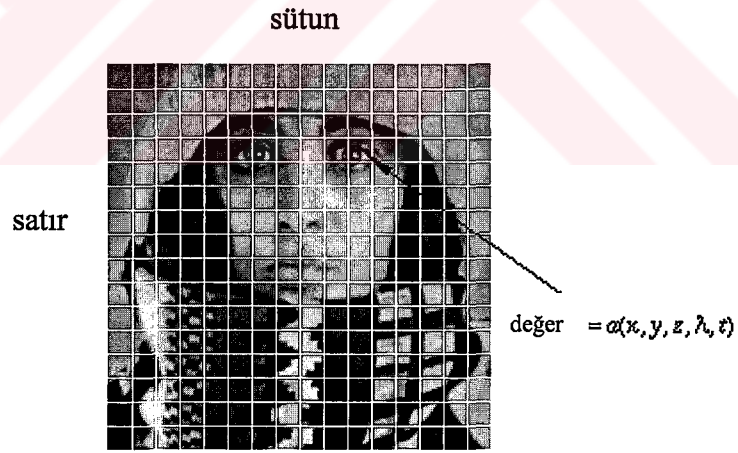
Temel tanımlamalardan başlarsak, "gerçek dünya" da tanımlanmış bir görüntü iki reel değişkenin bir fonksiyonu olarak düşünülmüştür. Örneğin $a(x,y)$ de, reel koordinat eksenleri (x,y) deki görüntünün genliği a ile belirtilmiştir. Bir görüntü belki alt görüntüler içerebilir ve bazen Region-Of-Interest (ROIs), yada basit bölgelerden bahsedilebilir. Bu kavram şu gerçeği yansıtmaktadır ki; görüntüler sık sık bir bölge için temel olan her bir nesnenin toplamını içermektedirler. Gelişmiş bir görüntü işleme sistemi içinde seçilmiş bölgelerde özel görüntü işleme uygulamaları olması mümkündür. Böylece bir görüntü bölgesinin bir kısmı, başka bir kısım renk durumunu geliştirme işini yaparken, net olmayan hareketi saklı tutmuş olabilir.

Verilen bir görüntünün genliği hemen her zaman reel numaralar ya da tamsayı numaralarından biri olacaktır. Sonraki genellikle işlemin niceliklerinin sonucudur ki bu devam eden diziyi (0 ve 100% arası) yüzeylerin ayrık numarasına dönüştürür. Belirli görüntü biçimlendirme işlemleri içinde sinyal, doğal bir şekilde nicelik kazandırılmış genlik anlamına gelen foton saymayı kapsıyor olabilir. Manyetik rezonans görüntüleme gibi başka bir görüntü biçimlendirme prosedüründe direk fiziksel ölçme ürünü reel büyüklük ve reel fazın biçimi içinde bir kompleks sayıdır.

2.1.1. SAYISAL GÖRÜNTÜ TANIMLAMALARI

İki boyutlu (2D) ayrık uzayda tanımlanmış bir $a[m,n]$ sayısal görüntü, iki boyutlu sürekli uzay içinden bir örnekleme işlemi içinde bir analog görüntü olan $a(x,y)$ den elde edilmiştir ve bu örnekleme işlemi sıkça bir sayısallaştırma gibi işaret edilmiştir. Sayısal görüntü ile birleştirilmiş temel tanımlamalara bakacak olursak. Şekil 2.1.1 de sayısallaştırma işlemi sonucu görülmektedir [3].

2D sürekli görüntü $a(x,y)$ burada N satır ve M sütuna bölünmüştür. Satırların ve sütunların kesişmesi bir piksel ile belirtilmiştir. $a[m,n]$ değeri tamsayı koordinatlara $[m,n]$, $\{m=0,1,2,\dots,M-1\}$ ve $\{n=0,1,2,\dots,N-1\}$ ile paylaştırılmıştır. Gerçekte 2D sensörün dış görünüşünü etkileyen fiziksel sinyalin olduğunu düşüneceğimiz bir çok $a(x,y)$ durumu aslında derinlik, renk ve zamanı kapsayan bir çok değişkenin bir fonksiyonudur.



Şekil 2.1.1 Sürekli görüntünün sayısallaştırılması

Şekildeki görüntü $N=16$ satır ve $M=16$ sütuna bölünmüştür. Her piksele paylaştırılmış değer en yakın tamsayı değere yuvarlanmış piksel içindeki ortalama parlaklıktır. Bir tamsayı değer ile farklı yüzeyler şeklinde verilen koordinatlarda 2D sinyalin genliğini gösterme işlemi genellikle niceliklendirme genliği yada basit niceliklendirme gibi işaret edilir.

2.1.2. SIK KULLANILAN DEĞERLER

Sayısal görüntü işlemede karşılaştırılmış çeşitli parametreler için standart değerler vardır. Bu değerler video standartları vasıtasıyla, algoritmik gereksinimler vasıtasıyla yada istenilen sayısal devreyi korumakla kullanılmış olabilir.

Tablo 2.1.1 Sayısal görüntü parametrelerinin yaygın değerleri

<i>parametre</i>	<i>sembol</i>	<i>Tipik değerler</i>
Satırlar	N	256,512,525,625,1024,1035
Sütunlar	M	256,512,768,1024,1320
Gri bölge	L	2,64,256,1024,4096,16384

Oldukça sık görülen bir durum olarak $\{K = 8,9,10\}$ olduğunda $M=N=2^K$ durumunu gösterebiliriz. Bu, sayısal devreler yada fourier transform gibi kesin algoritmalar kullanımı ile harekete geçirilmiş olabilir.

Farklı gri bölgelerin numaraları genellikle 2 nin kuvvetleri şeklindedir. Parlaklık seviyelerinin binary gösterimindeki bitlerin sayısının B olduğu yerde $L=2^B$ gösterimi bu şekilde bir ifadedir. Ayrıca $B>1$ olduğu zaman gri-bölge görüntü olduğunu $B=1$ olduğunda ise binary görüntü olduğunu söyleriz. Bir ikili görüntüde iki gri bölge vardır ve bunlar işaret edilmiş olabilir. Örneğin “siyah” ve “beyaz” yada “0” ve “1” gibi.

2.1.3. GÖRÜNTÜ İŞLEMLERİNİN KARAKTERİSTİKLERİ

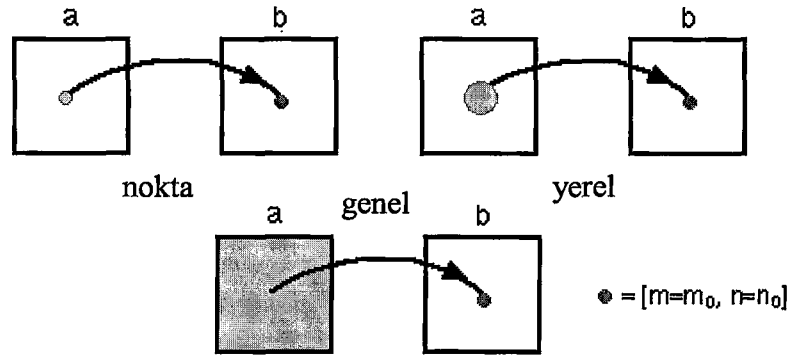
- İşlem tipleri
- Komşuluk tipleri

2.1.3.1. İŞLEM TİPLERİ

İşlem tipleri, sayısal görüntüleme bir giriş görüntüsü $a[m,n]$ nin bir çıkış görüntüsü $b[m,n]$ içine dönüştürülmesi şeklinde uygulanmış olabilir vade tablo 2.2 deki gibi üç kategoride sınıflandırılmış olabilir [3].

Tablo 2.1.2 Görüntü işlem tipleri. Görüntü boyutu= $N \times N$, komşuluk boyutu= $P \times P$ dir. Karmaşıklık işlemlerinde herbir piksel için açıkça belirtilmiştir.

İşlem	Tanımlama	Genel Karmaşıklık/piksel
*nokta	Özel koordinatlardaki çıkış değeri sadece aynı koordinattaki giriş değerine bağlıdır.	Sabit
*yerel	Özel koordinatlardaki çıkış değeri aynı koordinatlardaki komşuluk içindeki giriş değerlerine bağlıdır.	P^2
*genel	Özel koordinatlardaki çıkış değeri giriş görüntüsünün bütün değerlerine bağlıdır.	N^2




Şekil 2.1.2 Görüntü işlemlerinin çeşitli tiplerinin resimsel örneği

2.1.3.2. KOMŞULUK TIPLERİ

Komşuluk işlemleri modern sayısal görüntü işlemede bir anahtar rolü oynar. Bundan dolayı bir görüntü işleminde kullanılmış olması, çeşitli komşuluklarla nasıl ilişki kurulduğu ve görüntü örnekleme nasıl olduğu konularını anlamada önem teşkil eder.

- Dikdörtgensel (Rectangular) örnekleme ; Bir çok durumda görüntüler Şekil 2.1.1 deki resim gibi dikdörtgensel bir çerçeve içine döşenmiştir. Bu sonuçlar Şekil 2.1.3 a ve 2.2.3 b deki örnekleme tipidir.
- Altıgen biçimli (Hexagonal) örnekleme ; Şekil 2.1.3c de görülen alternatif bir örnekleme şeklidir. Altıgen şekillerden ibarettir.

İki örnekleme şemasında kapsamlı bir şekilde incelenmiş [1] ve her iki gösterim sürekli görüntü uzayının periyodik bağlanmasına olanak sağladığı görülmüştür. Donanım ve yazılım sebeplerinden dolayı metod olarak sadece dikdörtgensel örnekleme kalabilir. Yerel işlemler $a[m=m_o, n=n_o]$ nin komşuluğundaki piksel değerlerine bağlı olan $b[m=m_o, n=n_o]$ gibi bir çıkış piksel değeri üretir. Bir çok yaygın komşuluktan bazıları olan 4-bağlantılı komşuluk ve 8- bağlantılı komşuluk rectangular örnekleme olduğu takdirde ve 6-bağlantılı komşuluk Altıgen örnekleme olduğu takdirde oluşacaktır.



Şekil 2.1.3 Dikdörtgen ve Altıgen biçimli örnekleme şemaları.

2.1.4. VIDEO PARAMETRELERİ

Burada video kameralarından elde edilen birçok durgun görüntü verilmiş ve bunların dünya çapında en fazla kullanılan NTSC, PAL, SECAM gibi video standartlarından bahsedilmiştir.

Tablo 2.1.3 Standart video parametreleri

<i>standart</i>	NTSC	PAL	SECAM
<i>özellik</i>			
görüntü / second	29.97	25	25
ms / görüntü	33.37	40.0	40.0
lines / görüntü	525	625	625
(horiz./vert.) = aspect ratio	4:3	4:3	4:3
interlace	2:1	2:1	2:1
us / line	63.56	64.00	64.00

Bir interlaced (içiçe geçmiş, örülü) görüntüde tek sayı hattı (1,3,5,...) bölünmüş zamanın (20 ms in PAL) yarısı kısmına yerleştirilmiş ve çift sayı hattıda (2,4,6,...) kalan diğer yarısı kısma yerleştirilmiştir. Görüntüyü display etme yerleştirme biçimleri ile koordinatlandırılmış olmalıdır.

Bir video kaynağından gelen satırların sayısı (N) genellikle video görüntüsü içindeki hatlarla birebir uyum içindedir. Sütunların sayısı görüntüyü dijitize etmekte kullanılan elektronik türüne bağlıdır. Aynı video kameralar için farklı çerçeve tutucular $M=384,512$ yada 768 sütunlarını her bir hat için üretmiş olabilir.

2.1.5. ARAÇLAR

Bazı araçlar sayısal görüntülerin işlenmesinde temel teşkil ederler [3]. Bunlar;

- Konvülsiyon
- Fourier transformlar
- Kontur gösterimleri

2.1.5.1. KONVÜLSİYON

Çok boyutlu iki sinyalin konvülsiyonundan üretilen çıkış sinyalinin gösteriminin birkaç değişik şekli vardır. En yaygın olanı;

$$c = a \otimes b = a * b \quad (2.1)$$

İki boyutlu(2D) sürekli uzay için;

$$c(x, y) = a(x, y) \otimes b(x, y) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} a(\xi, \zeta) b(x - \xi, y - \zeta) d\xi d\zeta \quad (2.2)$$

İki boyutlu(2D) ayrık uzay için;

$$c[m, n] = a[m, n] \otimes b[m, n] = \sum_{j=-\infty}^{+\infty} \sum_{k=-\infty}^{+\infty} a[j, k] b[m - j, n - k] \quad (2.3)$$

2.1.5.1.1. KONVÜLSİYON ÖZELLİKLERİ

Konvülsiyon ile alakalı önemli matematiksel özellikler bulunmaktadır

Konvülsiyon commutative dir yani yer değiştirme özelliği vardır

$$c = a \otimes b = b \otimes a \quad (2.4)$$

Konvülsiyon associative dir yani birleşme özelliği vardır.

$$c = a \otimes (b \otimes c) = (a \otimes b) \otimes c = a \otimes b \otimes c \quad (2.5)$$

Konvülsiyon distributive dir yani dağılma özelliği vardır.

$$c = a \otimes (b + d) = (a \otimes b) + (a \otimes d) \quad (2.6)$$

Buradaki a,b,c,d ayrık yada sürekli uzaydaki görüntülerdir.

2.1.5.2. FOURIER TRANSFORMLARI

Fourier transformları(dönüştürücüleri) bir sinyalin başka bir görünümünü üretir. Özel olarak kompleks üstel ifadelerin toplamını göstermede avantaj sağlayan Euler formülü verilebilir.

$$e^{jq} = \cos(q) + j \sin(q) \quad (2.7)$$

$j^2 = -1$ olduğu durumda Fourier transformunun sinüs ve cosinüslerin toplamından oluşan 2D li bir sinyal ürettiğini söyleyebiliriz. İleri Fourier ve ters Fourier transformları için formül tanımlamaları aşağıda görülmektedir. Bir görüntü a ve onun Fourier transformu A ile verilsin. Bu takdirde ileri transformu sürekli yada ayrık olan uzaysal alandan her zaman sürekli olan frekans alanına gider.

$$A = \mathbf{F}\{a\} \quad (2.8)$$

Ters Fourier transformu frekans alanını gerisinden uzaysal alana gider

$$a = \mathbf{F}^{-1}\{A\} \quad (2.9)$$

Fourier transformları tek ve terslenebilir işlemlerdir.

$$a = \mathbf{F}^{-1}\{\mathbf{F}\{a\}\} \quad \text{ve} \quad A = \mathbf{F}\{\mathbf{F}^{-1}\{A\}\} \quad (2.10)$$

Uzaysal alan ve frekans alanı arasındaki ileri ve geri transform alma işlemi için özel formüller aşağıda verilmiştir.

2D sürekli uzay için;

$$\text{ileri} \quad A(u, v) = \iint_{-\infty-\infty}^{+\infty+\infty} a(x, y) e^{-j(ux+vy)} dx dy \quad (2.11)$$

$$\text{ters} \quad a(x, y) = \frac{1}{4\pi^2} \iint_{-\infty-\infty}^{+\infty+\infty} A(u, v) e^{+j(ux+vy)} du dv \quad (2.12)$$

2D ayrık uzay için;

$$\text{ileri} \quad A(\Omega, \Psi) = \sum_{m=-\infty}^{+\infty} \sum_{n=-\infty}^{+\infty} a[m, n] e^{-j(\Omega m + \Psi n)} \quad (2.13)$$

$$\text{ters} \quad a[m, n] = \frac{1}{4\pi^2} \iint_{-\pi-\pi}^{+\pi+\pi} A(\Omega, \Psi) e^{+j(\Omega m + \Psi n)} d\Omega d\Psi \quad (2.14)$$

2.1.5.2.1. FOURIER TRANSFORM ÖZELİKLERİ

- Faz ve genliğin (magnitüde) önemi
- Dairesel simetrik sinyaller

Fourier transformları ve ters fourier transformları beraber düşünüldüğünde özelliklerinde farklılıklar görülecektir. Fourier transform genelde reel frekans değerlerinin kompleks fonksiyonudur. Bu aşağıdaki gibi büyüklük ve faz bakımından yazılmış bir transform olabilir.

$$A(u, v) = |A(u, v)|e^{j\phi(u, v)} \quad A(\Omega, \Psi) = |A(\Omega, \Psi)|e^{j\phi(\Omega, \Psi)} \quad (2.15)$$

2D bir sinyal aynı zamanda kompleks olabilir ve böylece büyüklük ve faz bakımından yazılmış olabilir.

$$a(x, y) = |a(x, y)|e^{j\theta(x, y)} \quad a[m, n] = |a[m, n]|e^{j\theta[m, n]} \quad (2.16)$$

Eğer 2D sinyal reel ise Fourier transform simetriye sahiptir.

$$A(u, v) = A^*(-u, -v) \quad A(\Omega, \Psi) = A^*(-\Omega, -\Psi) \quad (2.17)$$

(*) sembolü kompleks eşlenik durumunu göstermektedir.

Reel sinyaller için şu eşitlikler mevcuttur.

$$\begin{aligned} |A(u, v)| &= |A(-u, -v)| & \phi(u, v) &= -\phi(-u, -v) \\ |A(\Omega, \Psi)| &= |A(-\Omega, -\Psi)| & \phi(\Omega, \Psi) &= -\phi(-\Omega, -\Psi) \end{aligned} \quad (2.18)$$

Eğer 2D sinyal reel ve çift ise Fourier transform reel ve çifttir.

$$A(u, v) = A(-u, -v) \quad A(\Omega, \Psi) = A(-\Omega, -\Psi) \quad (2.19)$$

Fourier ve ters Fourier transformları lineer işlemlerdir.

$$\begin{aligned} \mathcal{F}\{w_1 a + w_2 b\} &= \mathcal{F}\{w_1 a\} + \mathcal{F}\{w_2 b\} = w_1 A + w_2 B \\ \mathcal{F}^{-1}\{w_1 A + w_2 B\} &= \mathcal{F}^{-1}\{w_1 A\} + \mathcal{F}^{-1}\{w_2 B\} = w_1 a + w_2 b \end{aligned} \quad (2.20)$$

Burada a ve b 2D sinyaller ve w_1 ve w_2 keyfi kompleks sabitlerdir. Ayrık uzaydaki Fourier transformu periyodiktir ve periyotları 2π dir.

$$A(\Omega + 2\pi j, \Psi + 2\pi k) = A(\Omega, \Psi) \quad j, k \text{ sabit.} \quad (2.21)$$

Sinyaldeki enerji E uzaysal alanda ya da frekans alanında ölçülmüş olabilir. Parseval teoremi (2D sürekli uzayda):

$$E = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} |a(x, y)|^2 dx dy = \frac{1}{4\pi^2} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} |A(u, v)|^2 du dv \quad (2.22)$$

Parseval teoremi (2D ayrık uzayda):

$$E = \sum_{m=-\infty}^{+\infty} \sum_{n=-\infty}^{+\infty} |a[m, n]|^2 = \frac{1}{4\pi^2} \int_{-\pi}^{+\pi} \int_{-\pi}^{+\pi} |A(\Omega, \Psi)|^2 d\Omega d\Psi \quad (2.23)$$

Çok boyutlu sinyaller a,b,c ve bunların Fourier transformu A,B,C ise

$$\begin{aligned} c = a \otimes b &\quad \xleftrightarrow{\mathcal{F}} \quad C = A \cdot B \\ c = a \cdot b &\quad \xleftrightarrow{\mathcal{F}} \quad C = \frac{1}{4\pi^2} A \otimes B \end{aligned} \quad (2.24)$$

Eğer iki boyutlu sinyal a(x,y) uzaysal koordinatlarda ölçülmüş ise;

$$\begin{aligned} a(x, y) &\rightarrow a(M_x \cdot x, M_y \cdot y) \\ A(u, v) &\rightarrow A\left(\frac{u}{M_x}, \frac{v}{M_y}\right) / |M_x \cdot M_y| \end{aligned} \quad (2.25)$$

Eğer iki boyutlu sinyal $a(x,y)$ Fourier spektrumuna $A(u,v)$ sahipse;

$$A(u=0, v=0) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} a(x, y) dx dy$$

$$a(x=0, y=0) = \frac{1}{4\pi^2} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} A(u, v) dx dy \quad (2.26)$$


Aynı durumu için düşünülürse;

$$\frac{\partial a(x, y)}{\partial x} \stackrel{F}{\leftrightarrow} j u A(u, v) \quad \frac{\partial a(x, y)}{\partial y} \stackrel{F}{\leftrightarrow} j v A(u, v)$$

$$\frac{\partial^2 a(x, y)}{\partial x^2} \stackrel{F}{\leftrightarrow} -u^2 A(u, v) \quad \frac{\partial^2 a(x, y)}{\partial y^2} \stackrel{F}{\leftrightarrow} -v^2 A(u, v) \quad (2.27)$$

2.1.5.2.1.1. FAZ VE BÜYÜKLÜĞÜN ÖNEMİ

Denklemler kompleks olabilecek bir görüntünün Fourier transformunu gösterirler. Aşağıdaki Şekil 2.1.4 de bu durum resim ile gösterilmiştir ve burada (a) da orijinal görüntü $a[m,n]$, (b) de logaritmik olarak ölçülmüş büyüklük ve (c) de faz gösterilmektedir.




(a) orjinal (b) $\log(|A(\Omega, \Psi)|)$ (c) $\Phi(\Omega, \Psi)$

Şekil 2.1.4 Fourier transformu çıktıları

Büyüklük ve faz fonksiyonlarının her ikisinde bir görüntünün kendi Fourier transformundan yeniden yapılandırılmasını tamamlamak için gerekli fonksiyonlardır. Şekil 2.1.5 a, Şekil 2.1.4 a daki görüntünün yeniden temel büyüklük bilgisi üzerine

düzenlenmesini göstermek te Şekil 2.1.5 b ise Şekil 2.1.4 b deki durumun yeniden faz bilgisi üzerine düzenlenmesini göstermektedir.



(a) $\Phi(\Omega, \Psi) = 0$

(b) $|A(\Omega, \Psi)| = \text{sabit}$

Şekil 2.1.5 Görüntünün yeniden büyüklük ve faz bilgisi üzerine düzenlenmesi.

Ne büyüklük bilgisi ne de faz bilgisi görüntüyü tam olarak restore etmeye yeterli değildir. Sadece büyüklük (Şekil 2.1.5a) ile görüntü tanınmaz ve ciddi dinamik dizi problemine sebep olur. Sadece faz (Şekil 2.1.5b) ile görüntü ancak tanınabilir ki bu da şekildende görüleceği üzere tam nitelikli değildir.

2.1.5.2.1.2. DAİRESEL SİMETRİK SİNYALLER

Herhangi bir keyfi 2D $a(x,y)$ sinyali kutupsal koordinatlarda $a(r, \theta)$ şeklinde yazılmış olabilir.

Eğer 2D sinyali dairesel simetri gösterirse ;

$$a(x, y) = a(r, \theta) = a(r) \quad (2.28)$$

$r^2 = x^2 + y^2$ ve $\tan \theta = y/x$ olduğu durumda yukarıdaki şart gerçekleşir. Bu durum Fourier gösterimlerinin hesabında faydalı bir yoldur.

$A(u,v)$ Fourier transformu polar koordinatlarla $\omega_r^2 = u^2 + v^2$ ve $\tan \xi = v/u$ olduğu durumda ve $J_0(*)$ Bessel fonksiyonu gösteriyor ise

$$A(u, v) = \mathcal{F}\{a(x, y)\} = 2\pi \int_0^{\infty} a(r) J_0(\omega_r r) r dr = A(\omega_r) \quad (2.29)$$

şeklinde ifade edilebilir.

2.1.5.3. DIŞ HAT (KONTUR) GÖSTERİMİ


- Zincir (Chain) kod
- Zincir kod özellikleri
- Crack kod

Bir bölge yada nesne ile ilgili bir iş durumunda ,nesne üzerinde kolayca işleme ve ölçmeye olanak sağlayan gösterimler bulunabilir. Herbir durum için Şekil 2.1.6 da görüldüğü gibi bir görüntü gösterim şekli ile başladığımızı düşünelim. Konturlarla tanımlama vasıtası ile birkaç tane nesne ve bölge gösterimleri mevcuttur.

2.1.5.3.1. ZİNCİR KOD

Bu gösterim şekli Freeman [2] çalışmasına bağlı olarak belirtilmiştir. Burada konturu saat çalışması yönünde takip ederek kontur pikselinden bir sonrakine gidilir. Zincir kodun standart uygulaması için nesne pikseli olan bir kontur piksel düşünülürki bunun bir yada daha fazla 4-connected komşusu gibi nesnesiz bir arkaplan pikseline sahip olması gerekir. Sekiz olası yol ile birleştirilen kodlar zincir kodlarıdır ve buradaki x mevcut kontur piksel durumunu belirtmektedir. Bu durum için aşağıya bakacak olursak;

$$\text{Zincir kodlar} = \begin{matrix} & 3 & 2 & 1 \\ & 4 & x & 0 \\ & 5 & 6 & 7 \end{matrix}$$



Şekil 2.1.6 Gölge bölge (a) sürekliden (b) ayrık forma dönüştürülmüş ve daha sonra alternatif renklerde resimlenmiş (c) dışhat yada (d) run length gibi düşünülmüştür.

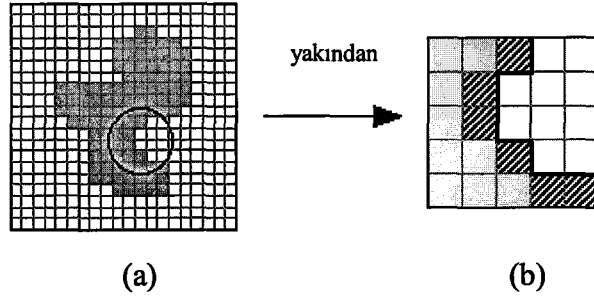
2.1.5.3.2. ZİNCİR KOD ÖZELLİKLERİ

- Çift kodlar {0,2,4,6} yatay ve dikey yönlere uyumlu, tek kodlar {1,3,5,7} çapraz yönlere uyumludur.
- Herbir kod 45 derecenin katları biçiminde açılabilir, burada bir pikselden bir sonrakine gidebilmek için hareket edilir..
- Eğer ardışık gelen iki zincir kod arasında bir değişiklik varsa kontürün yönü değiştirilmiştir ve bu nokta köşe olarak tanımlanmıştır.

2.1.5.3.3. CRACK KOD

Zincir kodlara alternatif olarak geliştirilmiş ve nesne ile birleştirilmiş kontür pikselleri ile arkaplan ile birleştirilmiş kontür piksellerini kullanmayan bir yapıdır. Crack kodlar sekiz yerine dört olası yön ile bir zincir kod gibi gösterilmiş olabilir.

$$\text{Crack kod} = \begin{matrix} 1 \\ 2 \times 0 \\ 3 \end{matrix}$$



Şekil 2.1.7 Crack kodlara ilişkin şekiller. (a) çalıştırılmış olan nesne içeren kısım (b) zincir kodları içinde kullanılmış kontur pikselleri çapraz şekilde karalanmışlardır. Burada crack siyah çizgi hattı ile gösterilmiştir.

Şekil 2.1.7b nin genişletilmiş kısmı için zincir kod tepeden aşağıya kadardır {5,6,7,7,0}.

Crack kod ise {3,2,3,3,0,3,0,0} dir.

2.1.6. GÜRÜLTÜ (NOISE)

Görüntüler modern sensörler ile elde edilir, ve belki de gürültü kaynaklarının bir değişikliği ile bozulabilir. Deterministik bozulmalara karşı stochastic değişimlerden söz edilebilir, bu bölümde modern elektro-optikler tarafından oluşturulmuş resimleri dağıttığımızı kabul edelim. Modern teknoloji değişken elektro-optikal aygıtlarla ilgili gürültü seviyelerini neredeyse önemsiz seviyeye düşürmeyi mümkün kılarken bir gürültü kaynağından kesinlikle kurtulamaz. Bunun sonucunda tüm gürültülerin elimine edildiği durum limiting durumudur. Bu kısımda fotonların, fotoelektron olarak adlandırılan elektronlar ürettiği modern Charge-Coupled Device (CCD) kameralarının kullanıldığını varsayacağız.

2.1.6.1. FOTON GÜRÜLTÜSÜ

İncelediğimiz fiziksel sinyal ışık tabanlı olduğu zaman ışığın quantum özelliği bilimsel bir rol oynar, gürültü problemi temelde, fotonun statik durumundan ortaya

çıkar ama biz verilen iki piksel için bunu kabul edemeyiz, fakat T uzunluğunun bağımsız inceleme aralığında aynı numaralı fotonlar sayılarak;

P fotonu için muhtemel bozulma T uzunluğuna bağlı olarak aşağıdaki denklemle ifade edilir.

$$P(p|\rho, T) = \frac{(\rho T)^p e^{-\rho T}}{p!} \quad (2.30)$$

Burada ρ oran veya saniyede ölçülen fotonların yoğunluk parametresidir.

2.1.6.2. ISISAL GÜRÜLTÜ

Bu gürültü çeşidinde elektronlar CCD materyalden termal titreşim boyunca bağımsız olabilir, ve daha sonra CCD kaynağı içinde hapsedilir. Bütünleşme zamanı T arttığında termal elektronların sayısı da artar ve bu yüzden termal gürültü meydana gelir.

2.1.6.3. CHIP ÜSTÜNDEKİ ELEKTRON GÜRÜLTÜSÜ

Bu gürültü sensörden okunan sinyalin (readout) oluşum süresince kaynaklanır, yani bir CCD chipinin alan etkili transistörü boyunca vardır.

$$Okunan\ gürültü \quad S_m(\omega) \propto \begin{cases} \omega^{-\beta} & \omega < \omega_{min} \quad \beta > 0 \\ k & \omega_{min} < \omega < \omega_{max} \\ \omega^{\alpha} & \omega > \omega_{max} \quad \alpha > 0 \end{cases}$$

Burada α ve β sabitler ve ω CCD chip'inden dış dünyaya transfer edilen sinyalin ışınsal frekansdır. Çok düşük readout rate'lerde ($\omega < \omega_{min}$) gürültü $1/f$ karakterine sahiptir.

2.1.6.4. KTC NOISE

Gürültü bir FET'in gate kapasitörü ile birleştirilir ve buna KTC gürültü denir ve bu önemli olabilir. Bu gürültü voltajının maksimum (RMS) değeri

$$KTC \text{ gürültü (voltage)} \quad \sigma_{KTC} = \sqrt{\frac{kT}{C}} \quad (2.31)$$

ile verilir.

Burada C FET gate switch kapasitansı, k boltzmann sabiti, ve T K içinde ölçülmüş CCD chip'inin mutlak sıcaklığıdır. $Q = C \cdot V = N_e \cdot e^-$ ilişkisi kullanılarak KTC gürültüsünün çıkış max(rms) değeri fotoelektronların (N_e) sayılarının terimleri içinde belirtilir.

$$KTC \text{ noise (electrons)} \quad \sigma_{N_e} = \frac{\sqrt{kTC}}{e^-} \quad (2.32)$$

Burada e^- elektron yüküdür , $C = 0.5$ pF ve $T = 233$ K için $N_e = 252$ elektron verir. verir. Bu değer sinyal readout'u ve bütünleşme zamanı esnasında her piksel için oluşan anlık bir gürültüdür [3] .

2.2. YAPAY SİNİR AĞLARI

Yapay Sinir Ağları (YSA), beynin fizyolojisinden yararlanılarak oluşturulan bilgi işleme modelleridir. Literatürde 100'den fazla yapay sinir ağı modeli vardır . Bazı bilim adamları, beynimizin güçlü düşünme, hatırlama ve problem çözme yeteneklerini bilgisayara aktarmaya çalışmışlardır. Bazı araştırmacılar ise, beynin fonksiyonlarını kısmen yerine getiren bir çok modelleri oluşturmaya çalışmışlardır .

YSA'ların öğrenme özelliği, araştırmacıların dikkatini çeken en önemli özelliklerden birisidir. Çünkü herhangi bir olay hakkında girdi ve çıktılar arasındaki ilişkiyi, doğrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hiç görülmemiş olayları, önceki örneklerden çağrışım yaparak ilgili olaya çözümler üretebilme özelliği YSA'lardaki zeki davranışın da temelini teşkil eder .

1943 yılında bir nörobiyolojist olan Warren McCulloch ve bir istatistikçi olan Walter Pitts, “*Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap*” başlıklı bir makale ile ilk dijital bilgisayarlara ışık tutmuştur. John Von Neumann bu makaleyi, “elektronik beyinler” için bir kopya olarak görmüştür. Yapay zeka alanındaki araştırmacılar içerisinde istisnai bir yeri olan Marvin Minsky, bu makaleden aldığı ilhamla makroskobik zeka fikrini ortaya atmış ve uzman sistemlerin doğmasına neden olmuştur. Bronx Yüksek Bilim Okulu'ndan Frank Rosenblatt, gözün hesaplamaları ile ilgilenmiştir. Bu bilim adamları, öğrenmenin ve zekanın herhangi bir özelliğinin simülasyonunda bilgisayarların aktif olarak nasıl kullanılabileceğini, 1956 yılında düzenlemiş oldukları ilk yapay zeka konferansında tartışmışlardır.

1959'da, Stanford üniversitesinden Bernard Widrow, basit nöron benzeri elemanlara dayanan ve “adaline” (A d a p t i v e L i n e a r N e u r o n) olarak adlandırılan bir adaptif lineer elemanı geliştirmiştir. Adaline ve iki tabakalı biçimi olan “madaline” (M u l t i p l e A d a l i n e) ses tanıma, karakter tanıma, hava tahmini ve adaptif kontrol gibi çok çeşitli uygulamalar için kullanılmıştır. Daha sonraları adaline, ayrık bir çıkış yerine sürekli bir çıkış üretmek için geliştirilmiştir. Widrow, telefon hatları üzerindeki ekoları elimine etmeye yarayan adaptif filtreleri geliştirmede, adaptif lineer eleman algoritmasını kullanmıştır. Bununla ilk defa YSA'lar gerçek bir probleme

uygulanmıştır. Helsinki Teknik Üniversitesi'nden Teuvo Kohonen , 1970'lerin ilk yıllarında adaptif öğrenme ve birleşik hafızalar üzerine temel çalışmalar yapmış ve bu çalışmaları ile danışmansız öğrenme metotlarının gelişmesine ışık tutmuştur .

Minsky ve Papert'in perseptron isimli kitaplarında , YSA'nın temel olarak ilgi çekici konular olmadığını belirtmeleri bir çok araştırmacının bu alanda çalışmaktan vazgeçmelerine sebebiyet vermiştir. YSA konusunda çalışmaya devam eden Grossberg , YSA modellerini yapılandırmak için nörolojik verinin kullanılması, algı ve hafıza için YSA tabanlı mekanizmaların önerilmesi, belirgin eşitliklerle bütünleşen bir sinaptik model için bir ilişkilendirici kural üzerinde çalışmıştır.

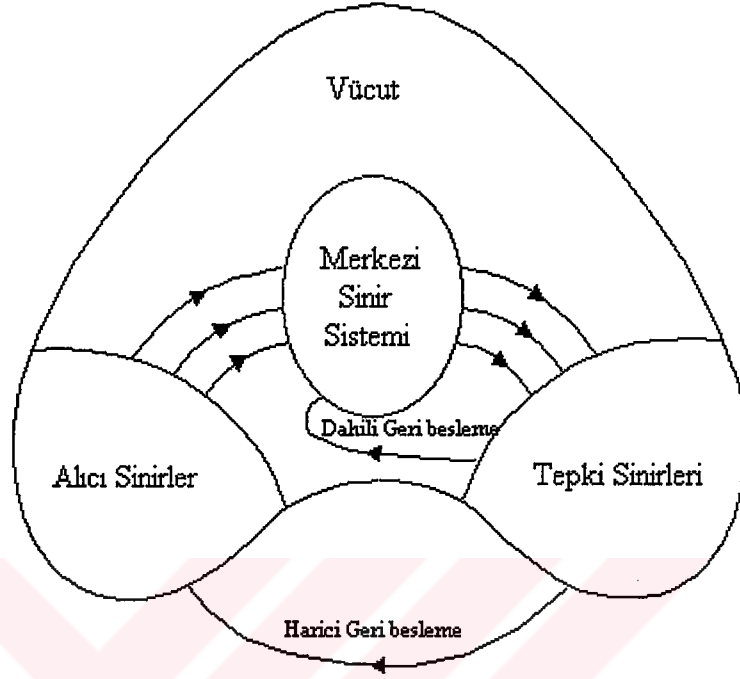
1982 yılında ilgi çeken bir başka gelişme, moleküler biyolojiden beyin kuramcılığına geçiş yapan bir model Caltech fizikçisi Hopfield tarafından sunulmuştur. Kendi adıyla anılan bir ağ yapısı mevcuttur ve bir çok alana uygulanmıştır.

1987 yılında yapılan ilk yapay sinir ağları sempozyumundan sonra YSA uygulamaları yaygınlaşmıştır. Günümüzde, YSA'larla ilgili araştırmalar yapan çok sayıda bilim adamı ve araştırma grupları vardır. Farklı bilim ve ilgi alanlarında çalışan birçok araştırmacı, birçok yeni gelişmeleri sunmaya devam edeceklerdir .

Takip eden bölümlerde biyolojik nörondan yapay nörona geçiş anlatılmaktadır.

2.2.1. BİYOLOJİK NÖRON YAPISI

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beyin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem olarak açıklanmaktadır . Alıcı sinirler (receptor), organizma içerisinden ya da dış ortamlardan algıladıkları uyarıları, elektriksel sinyallere dönüştürerek beyine iletirler. Tepki sinirleri (effector) ise, beyinin ürettiği elektriksel sinyalleri organizma çıktısı olarak uygun tepkilere dönüştürür. Şekil 2.2.1'de biyolojik sinir sisteminin blok şeması görülmektedir.



Şekil 2.2.1 Biyolojik sinir sisteminin blok gösterimi.

Sinir hücreleri nöron olarak bilinir. Nöron, özellikle beyin olmak üzere sinir sisteminin temel birimidir ve başlıca üç kısımdan oluşur. Bunlar:

- Gövde (cell body)
- Gövdeye giren sinyal alıcı lifler (dendrit),
- Gövdeden çıkan sinyal iletici lifler (axon).


YSA'lar, insan beyninin çalışma prensibi örnek alınarak geliştirilmeye çalışılmıştır ve aralarında yapısal olarak bazı benzerlikler vardır. Bu benzerlikler Tablo 3.1'de verilmiştir.

Tablo 2.2.1 Sinir sistemi ile YSA'nın benzerlikleri.

SİNİR SİSTEMİ	YSA SİSTEMİ
Neuron	İşlem elemanı
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Eleman çıkışı
Sinapslar	Ağırlıklar

Şekil 2.2.2'de bir nöron hücrelerinin yapısı verilmiştir. Bir nöronun yüzlerce, bazen de binlerce dendrit çıkabilir. Bunların uzunluğu genellikle bir milimetreden daha kısadır. Bazıları ise birkaç milimetre uzunluğa ulaşabilir. Dendritler çevre hücrelerden gelen sinyalleri (impulse) alıp, gövdeye ulaştırırlar. Her nöron, dendritler vasıtasıyla diğer bir çok nöronlardan gelen işaretleri alan ve birleştiren basit bir mikroişleme birimidir.

Beyin, sıkışık olarak arabağlaşımli milyarlarca (yaklaşık olarak 10^{11}) nöronun oluşmaktadır. Her eleman kendi aralarında oldukça çok sayıda nörona (eleman başına yaklaşık olarak 1000-10000 bağlantı) bağlanmıştır. Bir nöronun aksonu (çıkış yolu) ayrıştırılmıştır ve bir sinaps olarak adlandırılan bir jonksiyon vasıtasıyla diğer nöronların dendritlerine bağlanmıştır. Bu jonksiyon uçlarındaki iletim doğal olarak kimyasaldır ve işaretin miktarı, akson tarafından serbest bırakılan kimyasalların büyüklüğüne bağlı olarak transfer edilir ve dendritler vasıtasıyla alınır. Bu sinaptik büyüklük, beyin öğrenirken neyin modifiye edildiğini belirtir. Bu sinaps, beyin hafıza mekanizmasına dayanarak nöron içerisindeki bilginin işlenmesi ile birleştirilir.




Şekil 2.2.2 Nöron Modeli

T.C. YÜKSEK ÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ


2.2.2. AKTİVASYON FONKSİYONLARI

Şekil 2.2.3'de, bir hücrenin girdisine göre hücre çıkışını tanımlayan aktivasyon fonksiyonlarından 4 tanesi verilmiştir. Kullanılacak olan diğer fonksiyonların türevi alınabilir ve sürekli olması gerekmektedir. YSA'nın kullanım amacına uygun olarak tek veya çift yönlü aktivasyon fonksiyonları da kullanılabilir.

YSA'larda en çok kullanılan aktivasyon fonksiyonu Şekil 2.2.3a'da verilmiştir. Doğrusal YSA'larda ve katmanlı YSA'ların çıkış katmanında kullanılan doğrusal fonksiyon Şekil 2.2.3b'de verilmiştir ve işlemci elemanın girişini doğrudan işlemci elemanın çıkışı olarak verir. Bipolar özelliğe sahip olan tanjant hiperbolik fonksiyonu Şekil 2.2.3c'de gösterilmiştir. Giriş uzayının genişletilmesinde etkili bir aktivasyon fonksiyonudur. Şekil 2.2.3d'de görülen keskin sınırlayıcı aktivasyon fonksiyonu, mantıksal çıkış verir ve sınıflandırıcı ağlarda tercih edilir.




(a)



(b)



(c)



(d)

Şekil 2.2.3 YSA'larda en çok tercih edilen aktivasyon fonksiyonları a) sigmoid, b) doğrusal c) hiperbolik tanjant ve d) keskin sınırlayıcı

2.2.3. İŞLEMÇİ ELEMAN (YAPAY NÖRON)

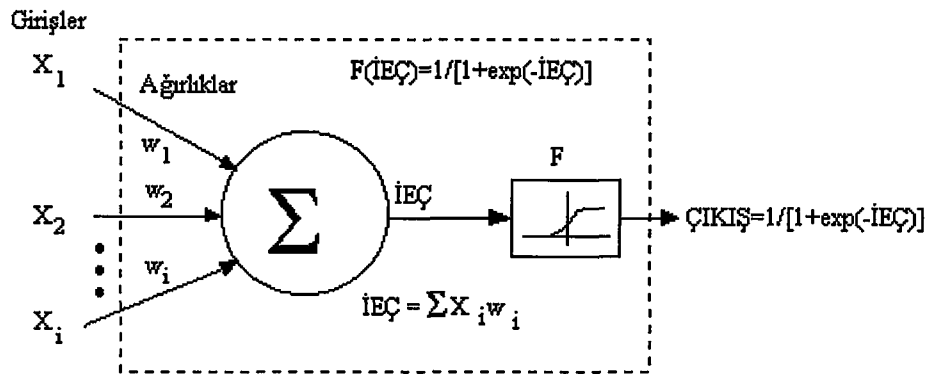
Bir YSA modelinin temel birimi, Şekil 2.2.4'de gösterilen işlem elemanıdır. Burada girişler dış kaynaklardan veya diğer işlem elemanlarından gelen işaretlerdir. Bu işaretler, kaynağına göre kuvvetli veya zayıf olabileceğinden ağırlıkları da farklıdır. YSA'da girilen giriş değerlerine önce toplama fonksiyonları uygulanır ve her bir işlem elemanının çıkış (İEÇ) değeri

$$\text{İEÇ} = \sum_{i=1}^N X_i W_{ij} - \theta_i \quad (3.1)$$

olarak bulunur. Burada X_i i'inci girişi, W_{ij} j'inci elemandan i'inci elemana bağlantı ağırlığını ve θ_i eşik (threshold) değerini göstermektedir. Daha sonra bu çıkış değerleri sigmoidal aktivasyon fonksiyonuna yani öğrenme eğrisine uygulanır. Sonuçta çıkış değeri aşağıdaki şekilde bulunur.

$$\text{ÇIKIŞ} = \frac{1}{1 + e^{-\text{İEÇ}}} \quad (3.2)$$

Transfer fonksiyonları olarak çoğunlukla, Şekil 2.2.3'de verilen fonksiyonlardan birisi kullanılabilir. Uygulamalarda, en çok *hiperbolik tanjant* veya *sigmoid* fonksiyonu kullanılmaktadır. Şekil 2.2.4'de işlemci eleman çıkışında kullanılan sigmoid fonksiyona göre çıkış değerinin hesaplanması gösterilmiştir. Bu işlemci elemanın çıkış değeri diğer işlemci elemanlarına giriş veya ağın çıkış değeri olabilir.



Şekil 2.2.4 Bir işlemci elemanı (yapay nöron).

2.2.4. YSA İLE HESAPLAMANIN ÖZELLİKLERİ

YSA'nın hesaplama özelliklerini, paralel dağılmış yapısından, öğrenilme ve genelleme yapma yeteneğinden aldığı söylenebilir. Genelleme, eğitim ya da öğrenme süresince kullanılmayan girişler için de YSA'nın uygun tepkileri üretmesi olarak tanımlanır. Bu özellikleri ile YSA'lar karmaşık ve çözümlenmesi güç problemleri de çözebilme yeteneğine sahiptir. Nesne tanıma , işaret işleme, sistem tanımlama ve denetimi gibi birçok mühendislik alanında YSA'lar, aşağıda belirtilen özellikleri nedeniyle başarılı olmuşlardır . [4]

2.2.4.1. DOĞRUSAL OLMAMA

YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik tüm ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlere çözüm getirmektedir.

2.2.4.2. ÖĞRENME

Burada öğrenmeden kasıt, ilgili problemdeki girdi-çıkı ilişkisini en güzel tanımlayacak optimum ağırlıkların bulunmasıdır. Problemden alınan örneklerden faydalanılarak ilgili problemi kendisine uygulanan örneklerden öğrenmeye çalışır. Probleme farklı bir çözüm sağlar [6].

2.2.4.3. GENELLEME

YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de belirtilen tepkiyi üretme kabiliyetine sahiptir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakteri verirler. Nöral hesaplamada hafızalar birleşiktir. Yani eğitilmiş ağa girişin sadece bir kısmı verilse bile, ağ hafızadan bu girişe en yakını seçerek tam bir giriş verisi alıyormuş gibi kabul eder ve buna uygun bir çıkış değeri üretir. Veri YSA'ya, eksik , bozuk veya daha önce hiç karşılaşmadığı şekilde verilse bile, ağ kabul edilebilir en uygun çıkışı üretecektir. Bu özellik ağın genelleştirme özelliğidir.

2.2.4.4. UYARLANABİLİRLİK

YSA ağırlıkları, uygulanan probleme göre değiştirilir. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir. Değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, işaret işleme, sistem tanımlama ve denetim gibi alanlarda etkin olarak kullanılır.

2.2.4.5. DAĞITILMIŞ BİRLEŞİK HAFIZA

YSA'ların en önemli özelliklerinden biri de bilgiyi depolamalarıdır. Nöral hesaplamalarda bilgi ağırlıklar üzerine dağıtılmıştır. Bağlantıların ağırlıkları nöral ağına hafıza birimidir. Bu ağırlıklar ağına o andaki sahip olduğu bilgiyi veya uygulanan örneklerden öğrenmiş olduğu davranışı verir. Bu bilgiler, ağıdaki birçok ağırlıklar üzerine (hafıza birimine) dağıtılır.

Eğitilmiş ağına, eğitimde kullanılmamış herhangi farklı bir giriş uygulanırsa ağına daha önceki girişlerden öğrenmiş olduğu davranış doğrultusunda beklenen çıkışa uygun bir çıkış değeri üretebilecektir.

2.2.4.6. HATA TOLERANSI

YSA'lar, çok sayıda işlemci elemanların bağlantısı paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki tüm bağlantılara dağılmıştır. Giriş data setinde bulunabilecek herhangi bir gürültü, bütün ağırlıklar üzerine dağıtıldığından dolayı, gürültü etkisi tolere edilebilir. Geleneksel yöntemlere göre hatayı tolere etme yetenekleri daha fazladır .

2.2.4.7. PARALEL İŞLEM YAPMA

YSA'lar, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini ve örnek tanıma, işaret işleme, sistem kimliklendirme ve denetim gibi gerçek zaman uygulamalarında kullanımını artırır .

2.2.5. YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI


YSA'lar, genel olarak birbirleri ile bağlantılı işlemci birimlerden veya diğer bir ifade ile işlemci elemanlardan (neurons) oluşurlar. Her bir sinir hücresi arasındaki bağlantıların yapısı ağı yapısını belirler. İstenilen hedefe ulaşmak için bağlantıların nasıl değiştirileceği öğrenme algoritması tarafından belirlenir. Kullanılan bir öğrenme kuralına göre, hatayı sıfıra indirecek şekilde, ağınlı ağırlıkları değiştirilir. YSA'lar yapılarına ve öğrenme algoritmalarına göre sınıflandırılırlar.

2.2.5.1. YSA'LARIN YAPILARINA GÖRE SINIFLANDIRILMASI

Yapay sinir ağları, yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde sınıflandırılırlar.

2.2.5.1.1. İLERİ BESLEMELİ AĞLAR


İleri beslemeli bir ağda işlemci elemanlar (İE) genellikle katmanlara ayrılmışlardır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. İE'ler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Şekil 2.2.5'de ileri beslemeli ağ için blok diyagram gösterilmiştir. İleri beslemeli ağlara örnek olarak Çok Katmanlı Perseptron (Multi Layer Perseptron-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir. [6, 8, 9]



Şekil 2.2.5 İleri beslemeli ağ için blok diyagram

2.2.5.1.2. GERİ BESLEMELİ AĞLAR

Bir geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Şekil 2.2.6'da bir geri beslemeli ağ görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara örnek olarak Hopfield [9] , SOM (Self Organizing Map), Elman [10]ve Jordan [11] ağları verilebilir .



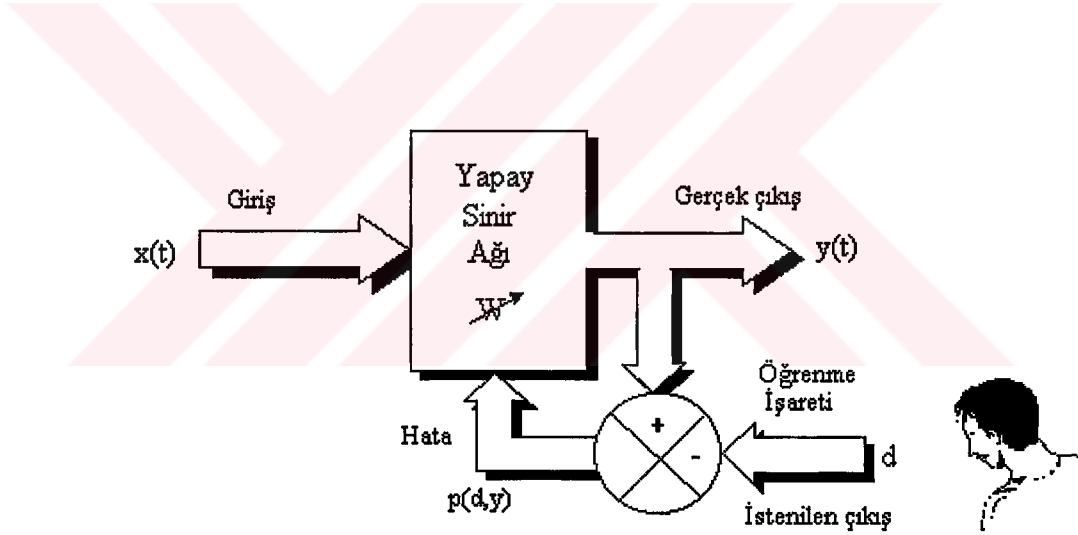
Şekil 2.2.6 Geri beslemeli ağ için blok diyagram

2.2.6.1. YSA'LARIN ÖĞRENME ALG. GÖRE SINIFLANDIRILMASI

Öğrenme; gözlem, eğitim ve hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır. O halde, birtakım metot ve kurallar, gözlem ve eğitime göre ağıdaki ağırlıkların değiştirilmesi sağlanmalıdır. Bunun için genel olarak üç öğrenme metodundan ve bunların uygulandığı değişik öğrenme kurallarından söz edilebilir. Bu öğrenme kuralları aşağıda açıklanmaktadır.

2.2.6.1.1. DANIŞMANLI ÖĞRENME (SUPERVISED LEARNING)

Bu tip öğrenmede, YSA'ya örnek olarak bir doğru çıkış verilir. İstenilen ve gerçek çıktı arasındaki farka (hataya) göre İE'ler arası bağlantıların ağırlığını en uygun çıkışı elde etmek için sonradan düzenlenebilir. Bu sebeple danışmanlı öğrenme algoritmasının bir "öğretmene" veya "danışmana" ihtiyacı vardır. Şekil 2.2.7'de danışmanlı öğrenme yapısı gösterilmiştir. Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri besleme (back propagation) algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir [12].




Şekil 2.2.7 Danışmanlı öğrenme yapısı.

2.2.6.1.2. DANIŞMANSIZ ÖĞRENME (UNSUPERVISED LEARNING)

Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmalarında, istenilen çıkış değerinin bilinmesine gerek yoktur. Öğrenme süresince sadece giriş bilgileri verilir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren desenler (patterns)

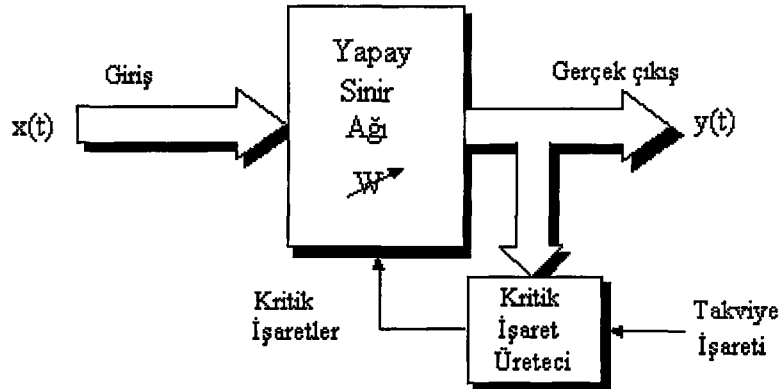
oluşturmak üzere ayarlar. Şekil 2.2.8’de danışmansız öğrenme yapısı gösterilmiştir. Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) [5, 7], öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir.



Şekil 2.2.8 Danışmansız öğrenme yapısı.

2.2.6.1.3. TAKVİYELİ ÖĞRENME (REINFORCEMENT LEARNING)

Bu öğrenme kuralı danışmanlı öğrenmeye yakın bir metoddur. Denetimsiz öğrenme algoritması, istenilen çıkışın bilinmesine gerek duymaz. Hedef çıktıyı vermek için bir “öğretmen” yerine, burada YSA’ya bir çıkış verilmemekte fakat elde edilen çıkışın verilen girişe karşılık iyiliğini değerlendiren bir kriter kullanılmaktadır. Şekil 2.2.9’da takviyeli öğrenme yapısı gösterilmiştir. Optimizasyon problemlerini çözmek için Hinton ve Sejnowski’nin geliştirdiği Boltzmann kuralı veya GA (Genetik Algoritma) takviyeli öğrenmeye örnek olarak verilebilirler.



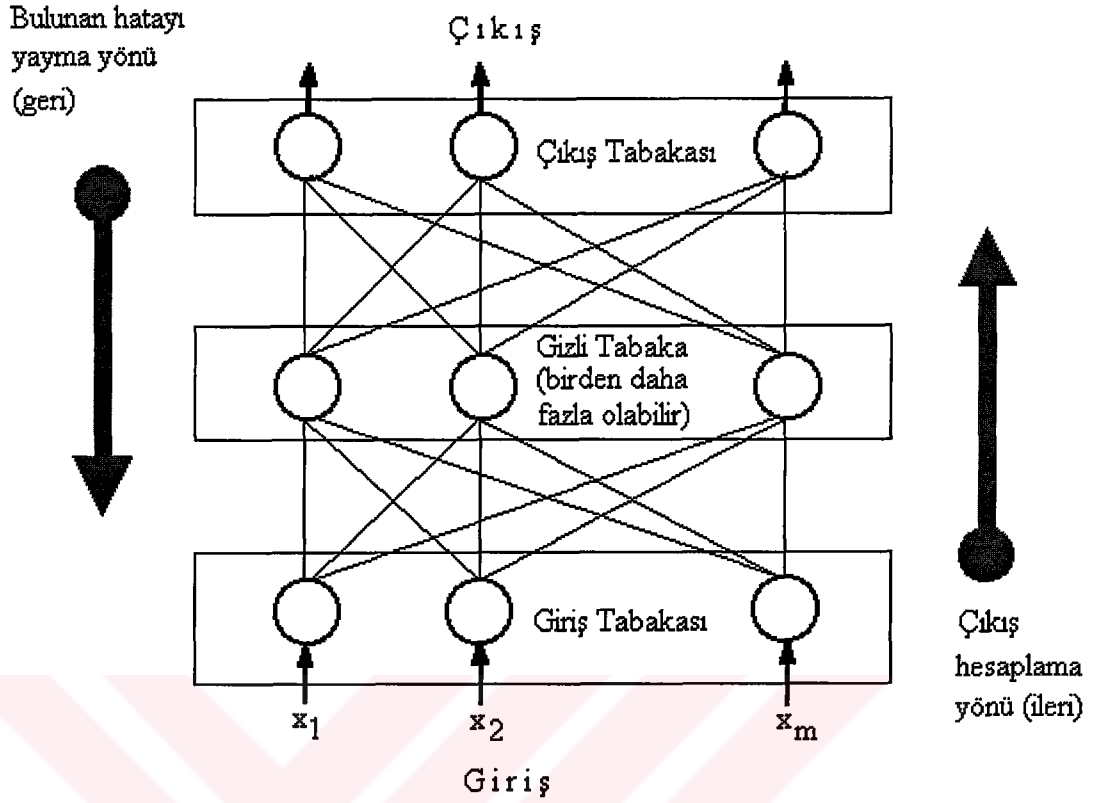
Şekil 2.2.9 Takviyeli öğrenme yapısı.

2.2.7. ÇOK KATMANLI PERSEPTRONLAR (MLP) VE ÖĞRENME ALG.

MLP'ler bir çok öğretilme algoritması kullanılarak eğitilebilirler. Burada, danışmanlı öğrenme algoritmaları olan geri-yayılım (BP:back-propagation), hızlı yayılım (QP-Quickprop), delta-bar-delta (DBD), genişletilmiş delta-bar-delta (EDBD-extended delta-bar-delta) ve takviyeli öğrenme metodu olan Genetik Algoritma (GA) mikroşerit antenlerin (MSA) parametrelerinin hesaplanmasında ve tasarımında kullanılan nöral modelleri eğitmede kullanılmıştır. Bu algoritmalar, bu bölümde detaylı olarak açıklanacaktır.

2.2.7.1. ÇOK KATMANLI PERSEPTRONLAR

Bir çok katmanlı perseptron sinir ağı modeli, Şekil 2.2.10'da gösterilmiştir. Bu ağ modeli özellikle mühendislik uygulamalarında en çok kullanılan sinir ağı modeli olmuştur. Bir çok öğretilme algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir. Bir MLP modeli, bir giriş, bir veya daha fazla ara ve bir de çıkış katmanından oluşur. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Bunun için ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı tamamen uygulanan problemler giriş sayısına bağlıdır. Ara katman sayısı ve ara katmanlardaki işlem elemanı sayısı ise, deneme-yanılma yolu ile bulunur. Çıkış katmanındaki eleman sayısı ise yine uygulanan probleme dayanılarak belirlenir.



Şekil 2.2.10 Geri yayılım MLP yapısı.

MLP ağlarında, ağa bir örnek gösterilir ve örnek neticesinde nasıl bir sonuç üreteceği de bildirilir (danışmanlı öğrenme). Örnekler giriş katmanına uygulanır, ara katmanlarda işlenir ve çıkış katmanından da çıkışlar elde edilir. Kullanılan eğitim algoritmasına göre, ağın çıkışı ile arzu edilen çıkış arasındaki hata tekrar geriye doğru yayılarak hata minimuma düşünceye kadar ağın ağırlıkları değiştirilir. İleri beslemeli ağlar, en genel anlamıyla giriş uzayıyla çıkış uzayı arasında statik haritalama yapar. Bir andaki çıkış, sadece o andaki girişin bir fonksiyonudur.

2.2.7.2. GERİ YAYILIM ALGORİTMASI

Bir çok uygulamalarda kullanılmış en yaygın öğretim algoritmasıdır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı en çok tercih edilen öğretim algoritmasıdır. Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır.

Tipik çok katlı geri yayılım ağı, daima; bir giriş tabakası, bir çıkış tabakası ve en az bir gizli tabakaya sahiptir. Gizli tabakaların sayısında teorik olarak bir sınırlama

yoktur. Fakat genel olarak bir veya iki tane bulunur . Geri yayılım algoritması , gradyen azalan ve MLP'leri eğitmede en çok kullanılan temel bir algoritmadır. Bu algoritmanın akış şeması Şekil 2.2.11'de verilmiştir. Eğitim işlemi ve eğitimden sonraki test işlemi bu akışa göre yapılır. Bu algoritma ile, i ve j kat işlem elemanları arasındaki ağırlıklardaki $\Delta w_{ji}(t)$ değişikliği hesaplanır. Bu ifade,

$$\Delta w_{ji}(t) = \eta \delta_j x_i + \alpha \Delta w_{ji}(t-1) \quad (3.3)$$

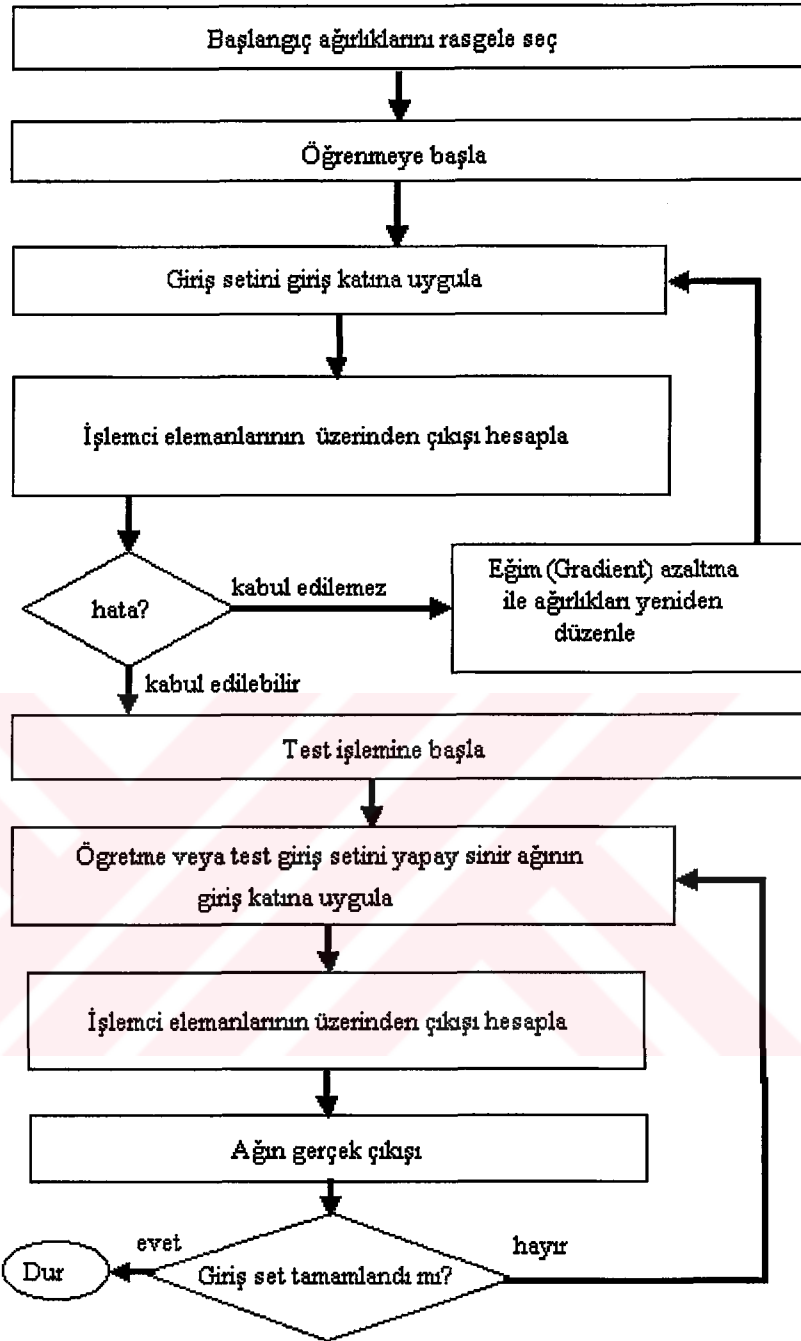
olarak verilir. Eşitlik (3.3)'de η öğrenme katsayısı, α momentum katsayısı ve δ_j ara veya çıkış katındaki herhangi bir j nöronuna ait bir faktördür. Çıkış katı için bu faktör aşağıdaki şekilde verilir.

$$\delta_j = \frac{\partial f}{\partial net_j} (y_j^{(t)} - y_j) \quad (3.4)$$

Burada, $net_j = \sum x_j w_{ji}$ ve $y_j(t)$ ise j işlemci elemanının hedef çıkışıdır. Ara katlardaki İE'ler için ise bu faktör,

$$\delta_j = \left(\frac{\partial f}{\partial net_j} \right) \sum w_{qj} \delta_q \quad (3.5)$$

olarak verilir. Ara katlardaki İE'ler için herhangi bir hedef çıkış olmadığından, eşitlik (3.4) yerine eşitlik (3.5) kullanılır. Bu duruma bağlı olarak çıkış katından başlayarak δ_j faktörü, bütün katlardaki İE'ler için hesaplanır. Daha sonra eşitlik (3.3)'deki formüle bağlı olarak, bütün bağlantılar için ağırlıkların güncelleştirilmesi gerçekleştirilir.



Şekil 2.2.11 Çok katmanlı bir perseptron geri yayılım akış şeması.

2.2.7.3. DELTA-BAR-DELTA KURALI

Delta-Bar-Delta (DBD) çok katmanlı perseptronlarda bağlantı ağırlıklarının yakınsama hızını arttırmak için kullanılan bir sezgisel yaklaşımdır. Deneysel çalışmalar, ağırlık uzayının her boyutunun tüm hata yüzeyi açısından tamamen farklı olabileceğini göstermiştir. Hata yüzeyindeki değişimleri açıklamak için, özellikle, ağın

her bağlantısı kendi öğrenme katsayısına sahip olmalıdır. Bu düşünce, tek ağırlık boyutu için uygun adım büyüklüğü, tüm ağırlık boyutları için uygun olmayabilir. Bununla birlikte, her bir bağlantıya bir öğrenme oranı atanarak ve bu öğrenme oranının zamanla değişmesine izin verilerek, yakınsama zamanını azaltmak için daha çok serbestlik derecesi sağlanmış olur. İleri beslemeli YSA yapıları çoğu zaman karmaşıktırlar. Ağdaki her bağlantı için en uygun öğrenme katsayıları kümesini belirlemek oldukça zaman alıcı olabilir. Eğimin geçmişteki değerlerini kullanarak, yerel hata yüzeyinin eğriliğini çıkarmak için sezgisellik uygulanabilir. Bir bağlantı için ağırlık değişimlerinin işareti, birkaç ardışık zaman adımları sırayla değiştiği zaman, bağlantı için öğrenme oranı azalmalıdır. Bağlantı ağırlık boyutu hata yüzeyi ile ilgili büyük bir eğriliğe sahiptir. Bağlantı ağırlık değişimleri bir kaç ardışık zaman adımları için aynı işarete sahip olduğundan bağlantı için öğrenme oranı artırılmalıdır. Ağırlık boyutu hata yüzeyi ile ilgili küçük bir eğriliğe sahiptir ve yüzey önemli bir mesafe için aynı doğrultudaki eğime göre devam eder [13].

Standart geri yayılım algoritmasında eğim bileşeni aşağıdaki şekilde verilir.

$$\delta(k) = \frac{\partial E(k)}{\partial w(k)} \quad (3.6)$$

Burada $E(k)$, k anındaki hata değerini, $w(k)$ bağlantı ağırlığını ve $\delta(k)$ ise ağırlık değişiminin eğim bileşenini göstermektedir. Standart geri yayılım algoritmasında bağlantı ağırlığı,

$$w(k+1) = w(k) + \alpha \delta(k) \quad (3.7)$$

olarak güncelleştirilir. Burada α sabit bir öğrenme oranıdır. DBD öğrenme kuralında, her bağlantı için değişken öğrenme oranı $\alpha(k)$ atanır ve bağlantı ağırlığının güncelleşmesi

$$w(k+1) = w(k) + \alpha(k) \delta(k) \quad (3.8)$$

şeklinde yapılır. Jacobs, her bağlantıda öğrenme hızının azalması ve artması için sezgiselliğin gerçekleştirilmesinde, $\delta(k)$ eğim bileşeninin ağırlıklı ortalamasını

kullanılmıştır. Bu ağırlıklı ortalama $\bar{\delta}(k)$ 'dir. Özellikle, ağırlıklı ortalama aşağıdaki şekilde gösterilmiştir.

$$\bar{\delta}(k) = (1 - \theta)\delta(k) + \theta \bar{\delta}(k - 1) \quad (3.9)$$

Burada, θ konveks ağırlık faktörüdür. Sezgisel açıdan, önceki eğim bileşeninin üstel artması ve şu anki eğim bileşeni aynı işaretli ise, öğrenme oranı κ sabiti ile artan ağırlıkla birleştirilir. Mevcut eğim bileşeni üstel ortalamadan farklı işaretli ise, öğrenme oranı mevcut değeri ile orantılı olarak azalır. Bu öğrenme oranının güncelleştirilmesi aşağıdaki eşitlikle tanımlanmıştır.

$$\Delta\alpha(k) = \begin{cases} \kappa & \bar{\delta}(k - 1) \delta(k) > 0 \\ -\varphi\alpha(k) & \bar{\delta}(k - 1) \delta(k) < 0 \\ 0 & \text{diğer} \end{cases} \quad (3.10)$$

Burada, κ öğrenme katsayısı artma faktörü, φ öğrenme katsayısı azaltma faktörü, $\alpha(k)$ k anındaki öğrenme oranını göstermektedir. Eşitlik (3.10)'dan görülebileceği gibi algoritma, öğrenme katsayılarını lineer olarak artırmakta, fakat geometrik olarak azaltmaktadır.

2.2.7.4. GENİŞLETİLMİŞ DELTA-BAR-DELTA (EXTENDED DBD)

Genişletilmiş Delta-Bar-Delta (EDBD) öğretim algoritması, eğitimde belirli bir anda epoch genel hatayı hesaplayarak hata düzeltme özelliğine sahiptir. Belirli bir andaki (ya da herhangi bir anda) ölçülen hata, bir önceki anda bulunan hatadan büyük ise ağırlıklar bir önceki ağırlık değerlerini alır. Daha iyi sonuçlar elde etmek için hata düzeltme özelliğine dayanıklılık (patience) faktörü eklenmiştir. Her periyottaki (epoch) hatayı test etmek yerine daha önce iyileştirilme işlemi yapıldığından hata, n periyotta test edilir.

EDBD'nin DBD'den farkı aşağıda özetlenmiştir.

- Sezgisel momentum kullanılır.
- Ağırlık uzayında büyük atlamalar ortadan kaldırılmıştır.
- Geometrik azaltma büyük (amacı aşan) atlamaları engellemede yeterince hızlıdır.
- EDBD'de, her bir bağlantıdaki momentum hızı $\mu(k)$ ve öğrenme hızı $\alpha(k)$ zamanla değişmektedir. DBD ile karşılaştırmak için standart delta kuralı ile verilen momentum için bağlantı ağırlıklarının değiştirilmesi

$$\Delta w(k+1) = \alpha \delta(k) + \mu \Delta w(k) \quad (3.11)$$

değerinin ağırlıklara katkısıyla

$$w(k+1) = w(k) + \Delta w(k+1) \quad (3.12)$$

elde edilebilir. Burada α ve μ sabittir. Bunun yanında EDBD için değişken öğrenme ve değişken momentum hızları aşağıdaki gibi elde edilebilir. Ağırlıklar,

$$\Delta w(k+1) = \alpha(k) \delta(k) + \mu(k) \Delta w(k) \quad (3.13)$$

değerinin bir önceki ağırlığa eklenmesiyle

$$w(k+1) = w(k) + \Delta w(k+1) \quad (3.14)$$

bulunur. Burada, $\mu(k)$ k zamanındaki bağlantı momentum hızıdır. Momentum hızı $\mu(k)$ ve öğrenme hızı $\alpha(k)$ aşağıdaki kurallara göre benzer şekilde ayarlanır. İlk önce, $\bar{g}(k)$ nin hesaplanması DBD algoritmasına göre belirlenir.

$$\bar{g}(k) = (1 - \theta) \delta(k) + \theta \bar{g}(k-1) \quad (3.15)$$

Burada θ konveks ağırlık faktörüdür. EDBD için öğrenme hızı değişimi:

$$\Delta\alpha(k) = \begin{cases} \kappa_{\alpha} \exp\{-\gamma_{\alpha}|\bar{\delta}(k)|\} & \text{eğer } \bar{\delta}(k-1)\delta(k) > 0 \\ -\varphi_{\alpha}\alpha(k) & \text{eğer } \bar{\delta}(k-1)\delta(k) < 0 \\ 0 & \text{diğer durumda} \end{cases} \quad (3.16)$$

formülünden elde edilir. Burada \exp , üstel fonksiyonunu, K_{α} , sabit öğrenme hızı skala faktörünü φ_{α} , sabit öğrenme hızı azaltma faktörü ve γ_{α} , sabit öğrenme hızı üstel faktörünü göstermektedir.

Benzer şekilde, k zamanındaki momentum hızı değişimi,

$$\Delta\mu(k) = \begin{cases} \kappa_{\mu} \exp\{-\gamma_{\mu}|\bar{\delta}(k)|\} & \text{eğer } \bar{\delta}(k-1)\delta(k) > 0 \\ -\varphi_{\mu}\mu(k) & \text{eğer } \bar{\delta}(k-1)\delta(k) < 0 \\ 0 & \text{diğer durumda} \end{cases} \quad (3.17)$$

ifadesinden bulunabilir. Burada, K_{μ} , sabit momentum hızı skala faktörünü φ_{μ} , sabit momentum hızı azaltma faktörü ve γ_{μ} , sabit momentum hızı üstel faktörünü göstermektedir.

Şuna da dikkat edilmelidir ki öğrenme ve momentum hızları, onların azalması ve artmasını kontrol eden farklı sabitlere sahiptir. $\bar{\delta}(k)\delta(k)$ 'nin işareti sezgisel olarak artma mı yoksa azalma mı olduğunu tespit etmek için kullanılır. Azalmanın ayarlanması DBD'nin kurallarına göre belirlenir. Ancak öğrenme ve momentum oranlarının artırılması $|\bar{\delta}(k)|$ 'nin üstel azalan fonksiyonu olarak değiştirilir. Böylece, küçük eğimli bölgelerde, büyük eğimli bölgelere nazaran daha büyük artırımlar yapılabilecektir. Bu, atlama problemi için kısmi bir çözümdür.

Ağırlık uzayında, osilasyonları ve aşırı atlamaları engellemek için, üst sınırlar her bir bağlantı öğrenme hızları ve momentum hızları üzerinde belirlenir. Matematiksel ifadesi, tüm bağlantılar için aşağıdaki gibidir.

$$\alpha(k) \leq \alpha_{\max} \quad (3.18)$$

$$\mu(k) \leq \mu_{\max} \quad (3.19)$$

Burada, α_{\max} öğrenme katsayısının üst sınırı ve μ_{\max} ise momentum katsayısının üst sınırıdır.

Sonuç olarak, EDBD algoritmasına düzeltme özellikli bir hafıza yerleştirilmiştir. Kullanıldığı zaman, eğitime datalarının sunumu her iterasyondan sonra, hata değerlendirilir. Hata, $E(k)$ bir önceki minimum hatadan küçük ise ağırlıkları o anki en iyiler olarak hafızada saklanır. Düzeltme tolerans parametresi λ , düzeltme sürecini kontrol eder. O andaki hata önceki minimum hatayı aşarsa, yani

$$E(k) > E_{\min} \lambda \quad (3.20)$$

olursa, tüm bağlantı ağırlıkları, hafızada saklı olan en iyi değerlerle değiştirilir. Ayrıca, öğrenme ve momentum hızları, düzeltmeyi başlatmak için azaltılır.

2.2.7.5. HIZLI YAYILIM (QUICKPROP)

Hızlı yayılım (Quickprop) algoritması, Scott Fahlman tarafından Carnegie Mellon Üniversitesi'nde geliştirilen ve Newton metoduna dayanan, çok katlı perseptronların eğitilmesi için kullanılan bir sezgisel öğretim algoritmasıdır. Sezgisel algoritmalar, tecrübeye ve eğitilmiş tahmine dayalı kurallar içermektedir. Bu algoritmalar optimum çözümü garanti edemeyip sadece ona yakın çözümü bulmayı garanti etmektedir.

Sezgisel metotları kullanmanın sağladığı bazı avantajlar şöyle özetlenebilir.

- 1- Sezgisel metotlar karar verici mekanizma için sadeleştirici olabilir.
- 2- Sezgisel metot, herhangi bir tam yöntemin parçası olarak öğrenme amacıyla kullanılabilir.
- 3- Gerçek dünya problemleri için her zaman matematiksel formülasyon kurmak çok kolay olmayabilir. Bu basitleştirme sonucu oluşan hata, bir sezgisel metodun sağladığı optimale yakın çözümün sahip olduğu hatadan daha büyük olabilir.

Problem uzayında mümkün olan en kısa sürede, bir çözüm bulmak için ağırlık uzayında eğimi (gradient) son derece küçük azaltmak gerekebilir. Bunun yerine çözümden fazla uzaklaşmaksızın mümkün olan en büyük adımlarla kısa sürede çözüme ulaşmak arzu edilir. Hata fonksiyonunun eğim derecesi biliniyorsa, güvenli bir şekilde ağırlık uzayında daha büyük adımla çözüme ulaşılabilir. Bu algorithmada iki geleneksel yaklaşım birleştirilerek çözülmüştür. Bunlar;

- Hesaplamanın geçmişteki durumu hakkında bazı sezgilere dayanan (genel veya her bir ağırlık için ayrı) dinamik olarak ağırlıkların ayarlanması.
- Her bir ağırlığa göre hatanın ikinci türevinin belirgin kullanımı
- Hızlı yayılım algoritması bir ikinci dereceli metoddan daha sezgiseldir ve çok az da olsa Newton-metoduna dayanan bu metotta iki kabul kullanılır.
- Her bir ağırlık için, ağırlık hata eğrisi kolları yukarı doğru açık olan bir parabol ile yaklaştırılabilir.
- Hata eğrisinin eğilimindeki değişim, diğer tüm ağırlıkların aynı andaki değişiminden etkilenmez.

Yukarıda bahsettiğimiz parabol, birbirinden bağımsız her bir ağırlık için şimdiki ve önceki hata eğimleri ve bu eğimlerin ölçüldüğü noktalar arasındaki değişim kullanılarak belirlenir. Daha sonra, algoritma doğrudan bu parabolün minimum noktasına atlar.

Genellikle hızlı yayılım algoritmasının performans testleri diğer tekniklerle karşılaştırıldığında oldukça iyidir. Bu algoritma, özellikle gürültü seviyesi az olan

dataya sahip problemlerde, EDBD kadar iyi sonuç vermektedir. Hızlı yayılım algoritması gürültü seviyesi fazla olan dataalı problemlerde çok iyi çalışır ancak gürültülü dataların bulunduğu problemlerde EDBD kullanılmalıdır .

Bu algorithmada ağırlık hızlandırma ve kırılması ihmal edilerek (t-1) den t'ye kadar ağırlıklardaki değişim,

$$\Delta w(t) = \epsilon L(t) + \alpha Q(t) \quad (3.21)$$

formülü ile verilir. Burada ϵ öğrenme katsayısı ve α ise momentum katsayısıdır.

$$L(t) = \begin{cases} h(t) & \text{eğer } h(t) h(t-1) \geq 0 \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.22)$$

ve

$$Q(t) = \begin{cases} \mu \Delta w(t-1) & \text{eğer } h(t) \left(h(t) - \left(\frac{\mu}{\mu+1} \right) h(t-1) \right) \geq 0 \\ \Delta q(t) & \text{diğer durumlarda} \end{cases} \quad (3.23)$$

eşitlikleri ile verilir. Bu ifadelerde μ momentum büyüme faktörü, $h(t) = \partial E / \partial w(t)$ eğimi ve

$$\Delta q(t) = \frac{\Delta w(t) h(t)}{h(t-1) - h(t)}$$

minimum adım miktarını göstermektedir. Buradan ağırlık fonksiyonunu güncelleştirmek için, delta ağırlık fonksiyonu ve ağırlık hızlandırma katsayısı işleme katılır.

$$w(t) = (1 - \delta)w(t-1) + \Delta w(t) \quad (3.24)$$

Burada δ hızlandırma katsayısıdır. Son olarak ağırlık çok küçük ise, 0 alınarak kırılır.

$$|\bar{w}(t)| < \kappa \text{ ise } \bar{w}(t) = 0 \text{ alınır.} \quad (3.25)$$

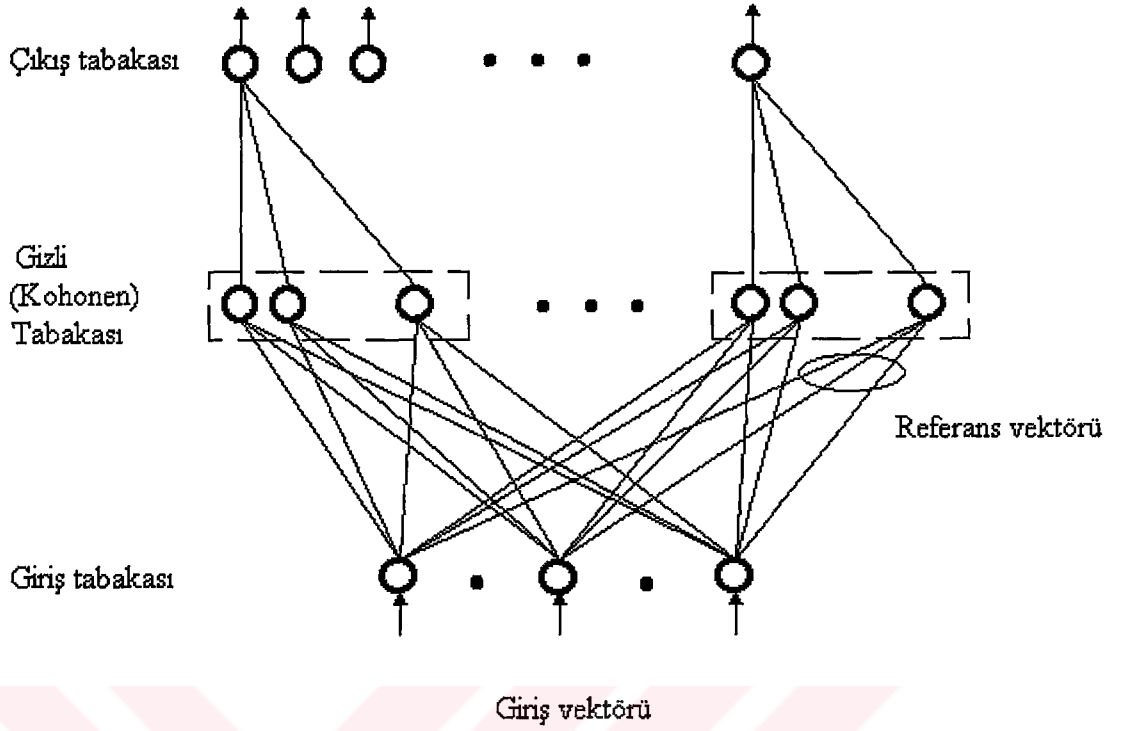
burada, κ ağırlık kırılma faktörüdür.

2.2.8. DİĞER YAPAY SİNİR AĞLARI

Bu kısımda, literatürde adı en çok geçen YSA'lara kısaca değinilecektir.

2.2.8.1. LVQ (LEARNING VECTOR QUANTIZATION)

Şekil 2.2.14, üç kattan oluşan LVQ ağını göstermektedir. Bu tabakalar, giriş, gizli tabaka ve çıkış tabakasıdır. LVQ ağı, giriş ve gizli tabaka arasında tamamen, gizli ve çıkış tabakası arasında da kısmen bağlıdır. Her çıkış işlemci elemanı farklı bir gizli işlemci eleman kümesine bağlıdır. Gizli ve çıkış işlemci elemanları arasındaki ağırlıklar 1'e sabitlenmiştir. Giriş-gizli işlemci eleman bağlantılarının ağırlıkları "referans" vektörlerinin elemanlarını oluşturur (her gizli işlemci elemana bir referans vektör atanmıştır). Ağın öğretilmesi esnasında bunlar yeniden değerler alırlar. Hem gizli işlemci elemanlar (bunlar Kohonen işlemci elemanları olarak da bilinir) hem de çıkış işlemci elemanları ikili (binary) çıkışa sahiptir. Ağa bir giriş deseni verildiğinde referans vektörü giriş desenine en yakın olan gizli işlemci eleman kümesi "1", diğerleri "0" üretir. "1" üreten çıkış işlemci elemanı giriş işaretini sınıflar ve her işlemci eleman ayrı bir sınıfa atanmıştır [14, 15].



Şekil 2.2.14 LVQ ağı

En basit LVQ öğretim prosedürü şu sırayla açıklanabilir.

- i. Referans vektörlerinin ağırlıklarının başlangıç değerlerini belirle,
- ii. Ağa giriş deseni uygula,
- iii. Giriş deseni ile her referans vektörü arasındaki “Öklit (Euclidian) uzaklığı”nı hesapla,
- iv. Giriş desenine en yakın referans vektörünün (-ki bu vektör kazanan gizli işlemci elemanının referans vektörüdür) ağırlıklarını yeniden düzenle. Eğer bu gizli işlemci eleman, o çıkış işlemci elemanına bağlı olduğu gizli işlemci eleman kümesine bağlı ise referans vektörünü giriş desenine daha yakın hale getir. Aksi takdirde referans vektörünü uzaklaştır,
- v. (ii) numaralı adıma yeni bir giriş deseni ile dön ve işlemlere bütün giriş desenleri sınıflandırılıncaya kadar devam et.

2.2.8.2. HOPFIELD AĞI

Şekil 2.2.15’de Hopfield ağının bir şekli gösterilmiştir. Bu ağ genellikle ikili (0 veya 1) ve bipolar (+1 veya -1) girişler kabul eder. Tek tabaka işlemci elemanları vardır ve her işlemci eleman bir diğerine bağlanmıştır. Bu da daha önceden belirtilen geri beslemeli yapıdır . Hopfield ağının eğitilmesi sadece bir adım alır ve w_{ij} ağırlıkları aşağıdaki gibi hesaplanır:

$$w_{ij} = \begin{cases} \frac{1}{N} \sum_{c=1}^P x_i^c x_j^c, & i \neq j \\ 0, & i = j \end{cases} \quad (3.27)$$

Burada w_{ij} , i işlemci elemanından j işlemci elemanına olan bağlantının ağırlığını, x_i^c c sınıfı için eğitime giriş deseninin i 'inci elemanını, P sınıf sayısını ve N de işlemci eleman sayısını gösterir. Denklem (3.27)'de $w_{ij}=w_{ji}$ ve $w_{ii}=0$ durumları ağın kararlılığını garantiler. Bilinmeyen bir bilgi ağa girildiğinde, ağın çıkışları bilinmeyen bir desen elemanlarına eşitlenir, yani;

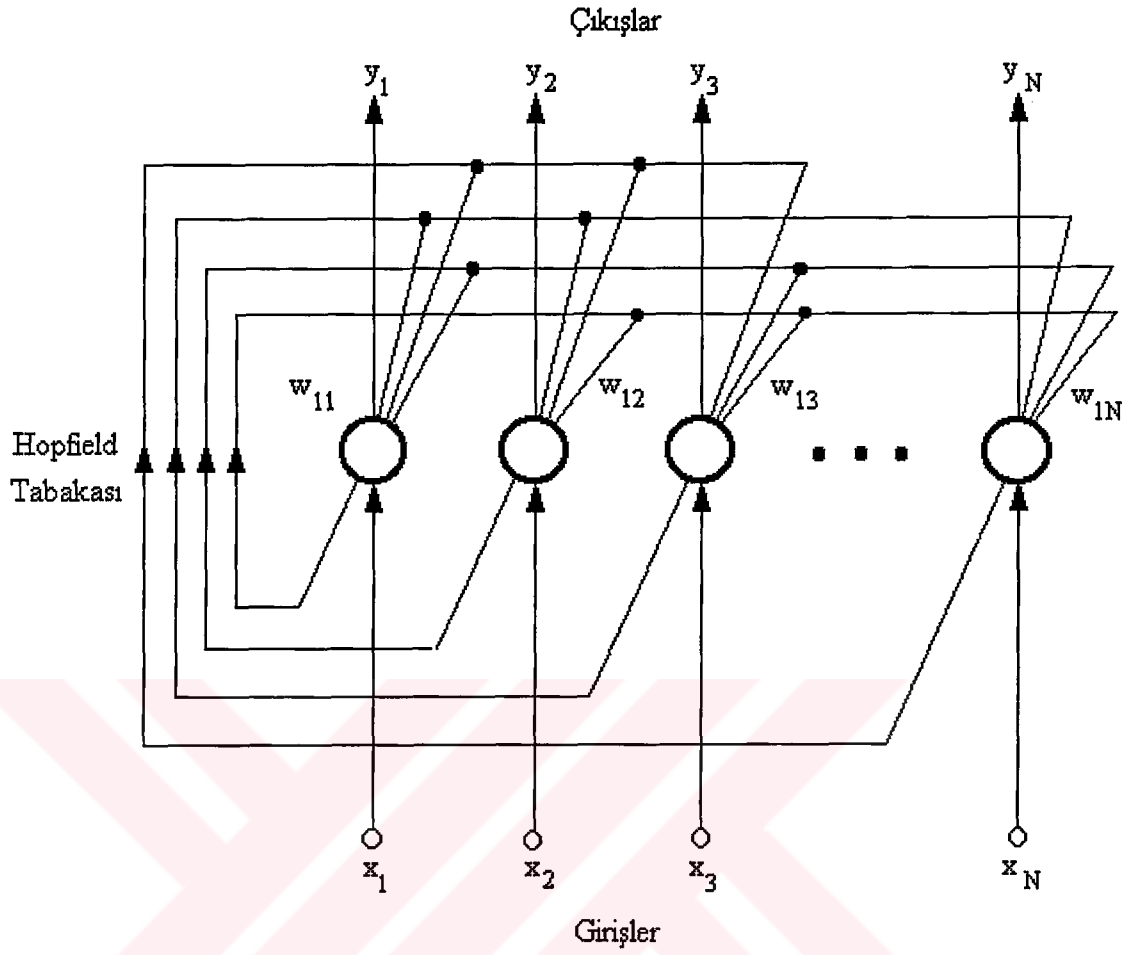
$$y_i(0) = x_i \quad 1 \leq i \leq N \quad (3.28)$$

Bu başlangıç değerleri ile başlayarak Hopfield ağı bir sonraki denklemi kullanarak minimum enerji durumuna geçmek için döngüye girer.

$$y_i(k+1) = f \left[\sum_{j=1}^N w_{ij} y_j(k) \right] \quad 1 \leq i \leq N \quad (3.29)$$

burada f aşağıdaki gibi tanımlanan keskin sınırlama (hard limiting) fonksiyonudur.

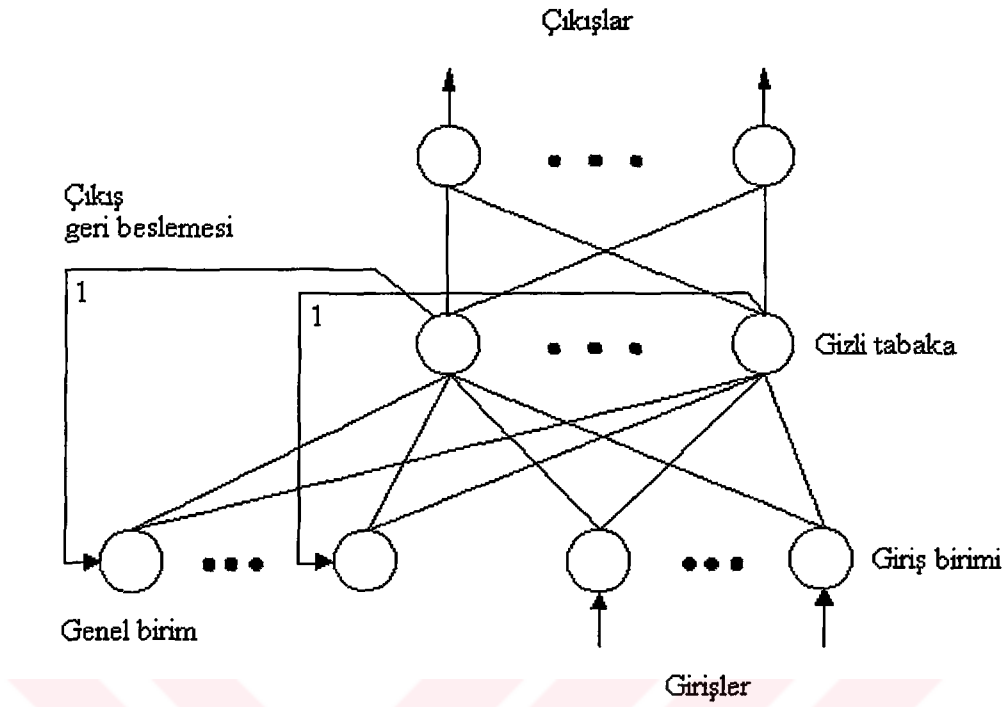
$$f(x) = \begin{cases} -1 & x < 0 \\ 1 & x > 0 \end{cases} \quad (3.30)$$



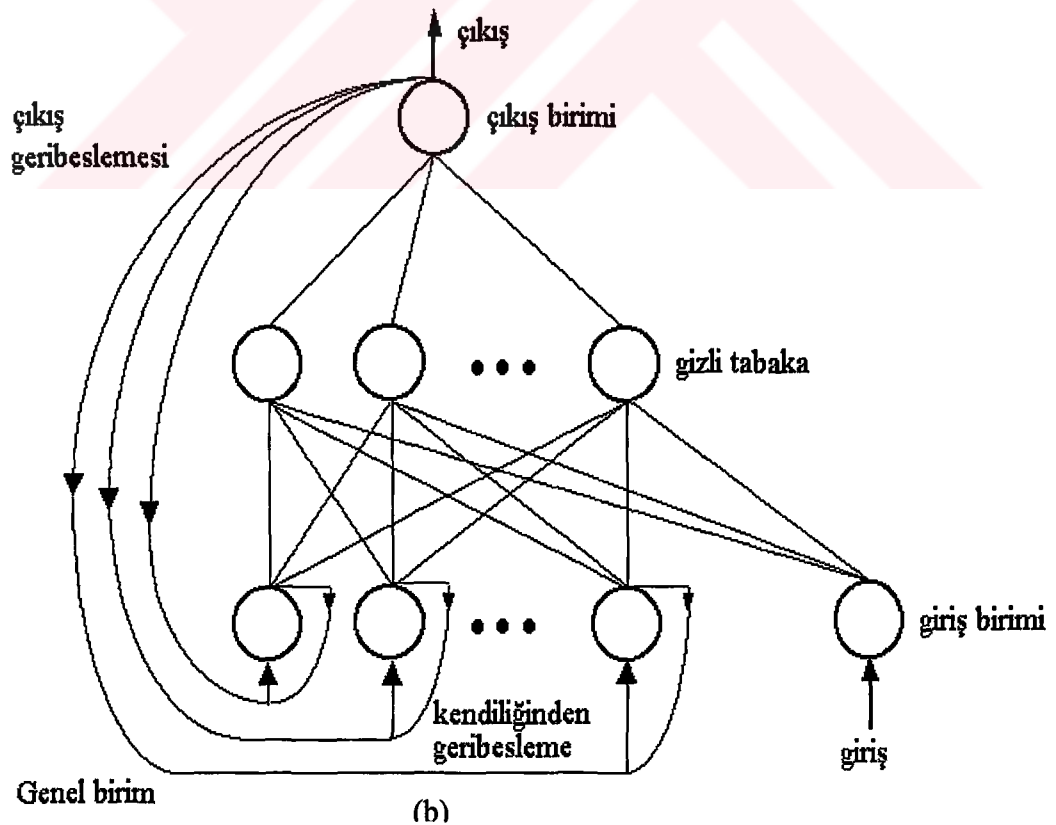
Şekil 2.2.15 Hopfield ağı

2.2.8.3. ELMAN VE JORDAN AĞLARI

Şekil 2.2.16a ve b Elman ve Jordan ağlarını göstermektedir. Bu ağlar, MLP'lere benzer bir yapıdadır ve çok katlıdır [10, 11]. Her iki ağda da gizli tabakaya ek olarak diğer bir "durum" tabakası denilen özel bir gizli tabaka daha vardır. Bu tabaka gizli tabakadan veya çıkış tabakasından geri besleme işaretleri alır. Jordan ağının aynı zamanda durum tabakasındaki her işlemci elemandan kendisine bağlantıları vardır. Her iki ağda da durum tabakasındaki işlemci elemanların çıkışları ileriye doğru gizli tabakaya verilmektedir. Eğer sadece ileri doğru bağlantılar göz önüne alınır ve geri besleme bağlantılarına sabit değerler verilirse, bu ağlar sıradan ileri beslemeli ağlar haline gelirler.



(a)



(b)

Şekil 2.2.16 Elman ve Jordan ağları a) Elman ağı, b) Jordan ağı

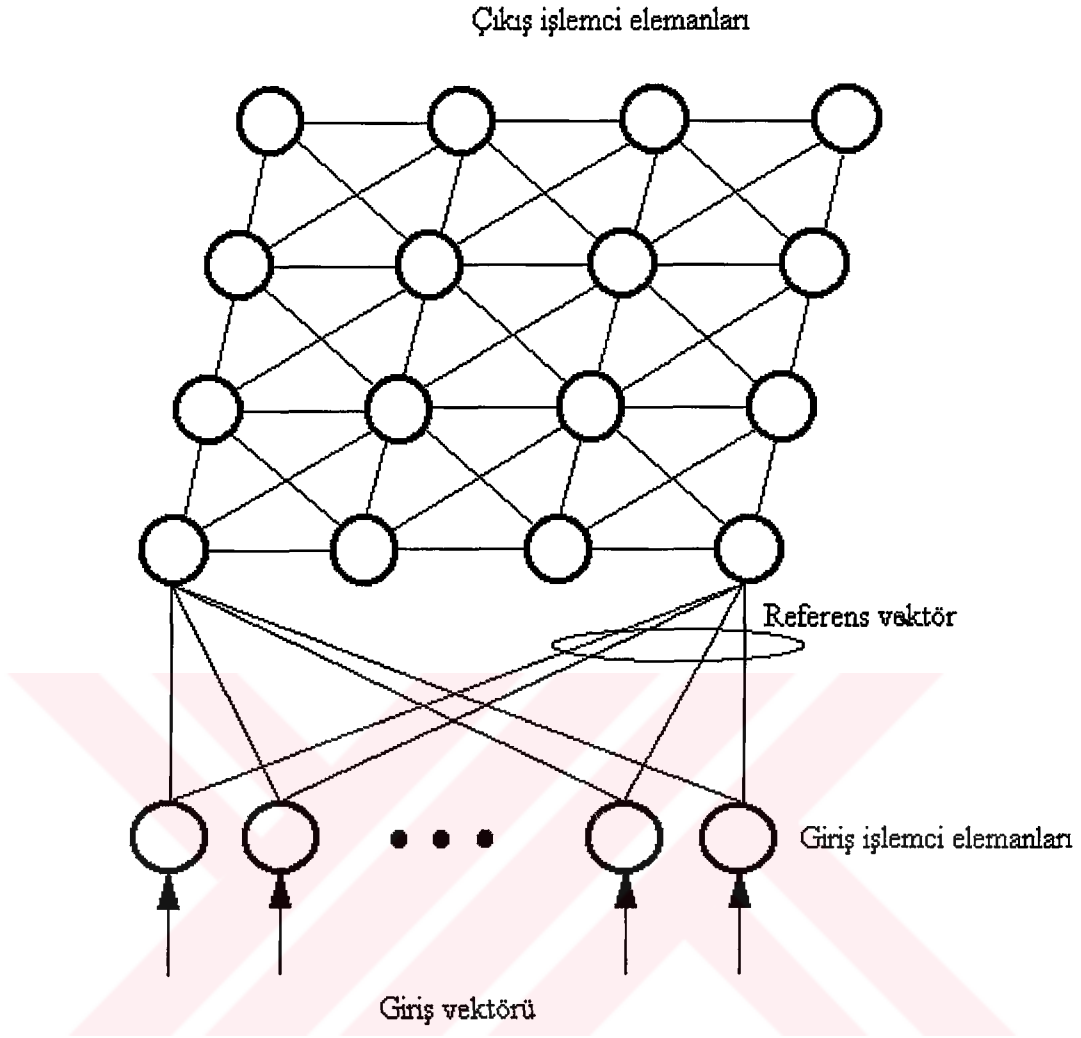
2.2.8.4. KOHONEN AĞI

Kohonen ağı, bir giriş tabakası ve bir de çıkış tabakası olmak üzere iki tabakadan oluşur. Bu ağ Şekil 2.2.17'da gösterilmiştir. Çıkış tabakasındaki işlemci elemanlar genellikle düzenli iki boyutlu aralıklar olarak düzenlenir. Çıkışdaki her İE, bütün giriş işlemci elemanlarına bağlıdır. Bağlantıların ağırlıkları verilen çıkış işlemci elemanı ile ilgili olan referans vektörünün elemanlarını oluşturur [5].

Kohonen ağının öğrenme adımları aşağıdaki gibidir.

- i. Çıkış İE'lerin bütün referans vektörlerini küçük rasgele değerlere çek,
- ii. Bir giriş desenini al,
- iii. Kazanan çıkış işlemci elemanını belirle (Bu giriş desenine en yakın referans vektörüne sahip işlemci elemandır. Referans vektörü ile giriş vektörü arasındaki öklit uzaklığı genellikle uzaklık ölçüsü olarak alınır.),
- iv. Kazanan işlemci elemanın ve onun komşularının referans vektörünü güncelleştir.

Bu referans vektörleri giriş vektörüne yaklaştırılır. Bu yaklaştırma (ayarlama) kazanan işlemci eleman için en fazla ve bu işlemci elemandan uzaklaştıkça daha azdır. Öğrenme ilerledikçe komşuların sayısı azalmakta ve öğrenme sonunda sadece kazanan işlemci elemanın referans vektörü ayarlanmaktadır. İyi öğrenmiş bir Kohonen ağında birbirine yakın çıkış işlemci elemanlarının referans vektörleri vardır. Öğrenmeden sonra bir etiketleme işlemine başlanır. Bilinen sınıfların giriş desenleri ağa giriş olarak verilir ve bu giriş desenleri tarafından aktif hale gelen çıkış işlemci elemanlarına bu sınıf etiketleri verilir. LVQ ağında ise bir çıkış işlemci elemanı eğer yarışmayı diğer çıkış işlemci elemanlarına karşı kazanırsa bir giriş deseni tarafından aktif hale getirildiği hatırlatılır.



Şekil 2.2.17 Kohonen ağı

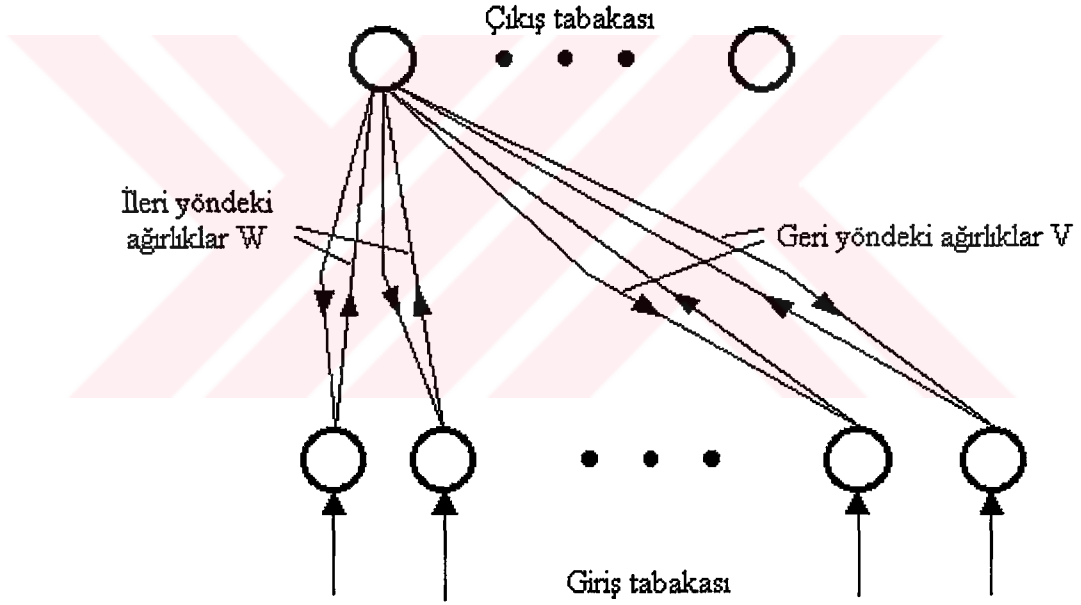
2.2.8.5. ART (ADAPTIVE RESONANCE THEORY) AĞI

ART ağının, ART-1, ART-2, Fuzzy-ART, MART gibi değişik çeşitleri vardır . Şekil 2.2.18'de ikili girişler kabul eden ART-1 gösterilmiştir. ART-2 gerçek değerler kabul etmektedir [16, 17, 18]. Şekil 2.2.18'de görüldüğü gibi, ART-1 ağının giriş ve çıkış olmak üzere iki tabakası vardır. İki tabaka birbirleriyle tamamen bağlantılıdır ve bağlantılar ileri ve geri yöndedir. i 'nci çıkış işlemci elemanlarının ileri yöndeki bağlantılarının ağırlıklarının oluşturduğu W_i vektörü, temsil ettiği sınıfın bir örneğini oluşturur. İleri bağlantılarının W_i vektörlerinin toplamı ART ağının uzun-dönem (long-term) hafızasını oluşturur. Bu vektörler, giriş desenine benzerlikleri ölçüsünde,

çıkış işlemci elemanlarını belirlerler. Çıkış işlemci elemanlarının geri bağlantılarının W_i vektörleri ise, giriş deseninin, hafızadaki desenine yeterince benzeyip benzemediğini (o sınıfa ait olup olmadığını) kesin olarak belirlemek için bir çeşit test “vigilance” amacıyla kullanılır. Bu test vektörleri diyebileceğimiz V_i vektörleri ART ağının kısa-dönem (short-term) hafızasını oluştururlar. W_i, V_i 'nin normalize edilmiş halidir.

$$W_i = \frac{V_i}{\varepsilon + \sum V_{ji}} \quad (3.31)$$

burada ε küçük bir sabittir ve V_{ji} , V_i 'nin j 'inci elemanıdır (yani i 'inci İE'den j 'inci giriş İE'na bağlantı ağırlığıdır).



Şekil 2.2.18 ART-1 ağı

2.2.9. YSA'NIN MÜHENDİSLİK UYGULAMALARI

YSA'lar birçok önemli mühendislik problemlerin çözümünde kullanılmışlardır. Aşağıda, kimya mühendisliği, inşaat ve yapı mühendisliği, elektrik ve elektronik mühendisliği, imalat ve makine mühendisliği, sistem ve kontrol mühendisliği alanlarında bulunan uygulamalarından bazıları bahsedilmektedir.

Kimya Mühendisliği; kimyasal reaktör seçimi, dinamik işlemlerde hata belirlenmesi, endüstriyel polimerisasyonda eritme akış indisi tahmini, endüstriyel mayalama işleminin modellenmesi, biyokimyasal işlemlerde mikrobik konsantrasyonların tahmininde uygulanmıştır.

İnşaat ve Yapı Mühendisliği; konstrüksiyon projelerinde kaynak seviyelerini belirleme, bir rezervuardan çıkışı kontrol, biyolojik bilgiler yardımıyla nehir suyu kalitesinin sınıflandırılması, nehirlerin akışının tahmin edilmesi, sonlu-eleman-temelli yapısal analiz işleminin modellenmesi, yapı malzemelerinin iç yapılarındaki çatlakların tespit edilmesi, depreme maruz betonarme çerçevelerde emniyetli yatay taşıyıcı tahmininde uygulanmıştır.

Elektrik ve Elektronik Mühendisliği; hastaların alarmla kontrolü, gürültülü resimlerin kalitesini artırma, görüntülerin sıkıştırılması, gürültü filtreleme ve resimlerdeki kenar bilgisinin çıkarılması, güç sisteminde harmoniklerin tahmini, gezgin haberleşme sisteminde kanal dağıtımı, ultrasonik müziklerden objelerin sınıflandırılması, optik okuyucu sistemler için resimlerin ön işleme alanlarında kullanılmıştır.

İmalat ve Makine Mühendisliği; metal kesme tezgahının kontrolü, akustik salınım ve iş parçası kuvvetiyle iş parçası yatağının kontrolü ve güç tüketimi ve iş parçası ivmesi, hücreli imalat için grup teknolojisi parça gruplarının tasarımı, hareket eden nesnelere için engelsiz yol planlaması, makine parametrelerinin optimizasyonu, makine arızalarının sınıflandırılması, malzemelerin ısı transferinin belirlenmesi, uçak kanat kutularının yapısının tasarımında uygulanmıştır.

Sistem ve Kontrol Mühendisliği; esnek kollu robotun kontrolü, bir model helikopterin havada kontrolü, çok değişkenli (mafsallı) robotun yörünge koordinasyonu, iki sıvı tank sisteminin akış seviye kontrolü, anestezi derinliği kontrolü ve ölçülmesi, bir robot için optimal yolun bulunması, banyo suyu sıcaklığının kontrolü, endüstriyel robot kontrolü, sistem kimliklendirme gibi birçok alanda uygulanmıştır.

Anten ve Uygulamaları; yapay sinir ağlarında bir dinamik öğrenme algoritması (DÖA) kullanılarak anten dizi elemanlarından elde edilen işaretler arasındaki faz farklılıklarının karşılaştırılmasıyla radar izleme gerçekleştirilmiştir. Mikrodalga

parlaklığına bağılı jeofiziksel parametrelerin tayini, DÖA sinir ağı kullanılarak gerçekleştirilmiştir. Uzaktan kontrollü görüntü sınıflama işlemi, danışmanlı DÖA ve danışmansız (ART2) öğrenme algoritmaları kullanılarak yapılmıştır. YSA'ları kullanarak anten dizi analizi yapılmıştır. Aynı zamanda, anten dizi tasarımında, genetik algoritma ve tabu araştırma algoritması kullanılmıştır. Osilatör YSA ile elektromagnetik işaretlerin etkileşim modelleri oluşturulmuştur.



2.3. BULANIK MANTIK

2.3.1. BULANIK MANTIK KAVRAMI


Bulanık mantık (Fuzzy Logic) kavramı ilk kez 1965 yılında California Berkeley Üniversitesinden Prof. Lotfi A.Zadeh'in bu konu üzerinde ilk makalelerini yayınlamasıyla duyuldu [19]. O tarihten sonra önemi gittikçe artarak günümüze kadar gelen bulanık mantık, belirsizliklerin anlatımı ve belirsizliklerle çalışılabilmesi için kurulmuş katı bir matematik düzen olarak tanımlanabilir. Bilindiği gibi istatistikte ve olasılık kuramında, belirsizliklerle değil kesinliklerle çalışılır ama insanın yaşadığı ortam daha çok belirsizliklerle doludur. Bu yüzden insanoğlunun sonuç çıkarabilme yeteneğini anlayabilmek için belirsizliklerle çalışmak gereklidir. Bulanık mantık ile matematik arasındaki temel fark bilinen anlamda matematiğin sadece aşırı uç değerlerine izin vermesidir. Klasik matematiksel yöntemlerle karmaşık sistemleri modellemek ve kontrol etmek işte bu yüzden zordur, çünkü veriler tam olmalıdır. Bulanık mantık kişiyi bu zorunluluktan kurtarır ve daha niteliksel bir tanımlama olanağı sağlar. Bir kişi için 36 yaşında demektense sadece orta yaşlı demek bir çok uygulama için yeterli bir veridir. Böylece azımsanamayacak ölçüde bir bilgi indirgenmesi söz konusu olacak ve matematiksel bir tanımlama yerine daha kolay anlaşılabilen niteliksel bir tanımlama yapılabilecektir. Bulanık mantıkta fuzzy kümeleri kadar önemli bir diğer kavramda linguistik değişken kavramıdır. Linguistik değişken "sıcak" veya "soğuk" gibi kelimeler ve ifadelerle tanımlanabilen değişkenlerdir. Bir linguistik değişkenin değerleri fuzzy kümeleri ile ifade edilir. Örneğin oda sıcaklığı linguistik değişken için "sıcak", "soğuk" ve "çok sıcak" ifadelerini alabilir. Bu üç ifadenin her biri ayrı ayrı fuzzy kümeleri ile modellenir.

Bulanık mantığın uygulama alanları oldukça geniştir. Sağladığı en büyük fayda ise "insana özgü tecrübe ile öğrenme" olayının kolayca modellenebilmesi ve belirsiz kavramların bile matematiksel olarak ifade edilebilmesine olanak tanınmasıdır. Bu nedenle lineer olmayan sistemlere yaklaşım yapabilmek için özellikle uygundur.

Bulanık mantık konusunda yapılan araştırmalar Japonya'da oldukça fazladır. Özellikle fuzzy process controller olarak isimlendirilen özel amaçlı bulanık mantık mikroişlemci çipi'nin üretilmesine çalışılmaktadır. Bu teknoloji fotoğraf makineleri,

çamaşır makineleri, klimalar ve otomatik iletim hatları gibi uygulamalarda kullanılmaktadır. Bundan başka uzay araştırmaları ve havacılık endüstrisinde de kullanılmaktadır. Yine bir başka uygulama olarak otomatik civatalamaların değerlendirilmesinde bulanık mantık kullanılmaktadır. Bulanık mantık yardımıyla civatalama kalitesi belirlenmekte, civatalama tekniği alanında bilgili olmayan kişiler açısından konu şeffaf hale getirilmektedir. Burada bir uzmanın değerlendirme sınırlarına erişilmekte ve hatta geçilmektedir. Fuzzy kuramının merkez kavramı fuzzy kümeleridir. Küme kavramı kulağa biraz matematiksel gelebilir ama anlaşılması kolaydır. Örneğin “orta yaş” kavramını inceleyerek olursak, bu kavramın sınırlarının kişiden kişiye değişiklik gösterdiğini görürüz. Kesin sınırlar söz konusu olmadığı için kavramı matematiksel olarak da kolayca formüle edemeyiz. Ama genel olarak 35 ile 55 yaşları orta yaşlılık sınırları olarak düşünülebilir. Bu kavramı grafik olarak ifade etmek istediğimizde karşımıza Şekil 2.3.1 deki gibi bir eğri çıkacaktır. Bu eğriye “aitlik eğrisi” adı verilir ve kavram içinde hangi değer hangi ağırlıkta olduğunu gösterir.

Bir fuzzy kümesi kendi aitlik fonksiyonu ile açık olarak temsil edilebilir. Şekilde görüldüğü gibi aitlik fonksiyonu 0 ile 1 arasındaki her değeri alabilir. Böyle bir aitlik fonksiyonu ile “kesinlikle ait” veya “kesinlikle ait değil” arasında istenilen incelikte ayarlama yapmak mümkündür.



Şekil 2.3.1 Yaşlara ait üyelik fonksiyonu

Bulanık mantık, adından anlaşılabilceği gibi mantık kurrallarının esnek ve bulanık bir şekilde uygulanmasıdır. Klasik (boolean) mantıkta bilindiği gibi, "doğru" ve "yanlış" yada "1" ve "0"lar vardır, oysa bulanık mantıkta, ikisinin arasında bir yerde olan önermeler ve ifadelere izin verilebilir ki, gerçek hayata baktığımızda hemen hemen hiçbir şey kesinlikle doğru veya kesinlikle yanlış değildir. Gerçek hayatta

önermeler genelde kısmen doğru veya belli bir olasılıkla doğru şeklinde değerlendirilir. Bulanık mantığa da zaten klasik mantığın gerçek dünya problemleri için yeterli olmadığı durumlar dolayısıyla ihtiyaç duyulmuştur.

Bulanık mantığın sistemi şu şekildedir. Bir ifade tamamen yanlış ise klasik mantıkta olduğu gibi 0 değerindedir, yok eğer tamamen doğru ise 1 değerindedir. (Ancak bulanık mantık uygulamalarının çoğu bir ifadenin 0 veya 1 değerini almasına izin vermezler, veya sadece çok özel durumlarda izin verirler.) Bunların dışında tüm ifadeler 0 dan büyük 1 den küçük reel değerler alırlar. Yani değeri 0.35 olan bir ifadenin anlamı %35 doğru %65 yanlış demektir.

Kompleks sistemleri basitleştirmenin bir yolu belli oranda hassassızlığa (imprecision), belirsizliğe (vagueness) ve kesinsizliğe (uncertainty) tahammül etmektir. Tabi ki ortaya çıkan sonuçlar mükemmel değildir ama çoğu kez modelleme problemini çözerler.

Bir belirsizliği ifade etmek için örnek olarak “Ali yaşlıdır” . Bu cümlemin anlamı bize Ali nin yaşını tam olarak ifade etmez. Bir belirsizlik söz konusudur. “Ali 55-60 yaşlarındadır” cümlesinde ise bir “hassassızlık” durumu vardır. Kesinsizlik ise olasılık kavramının bir getirisidir. Şans oyunlarında kesinsizlik söz konusudur.

2.3.2. BULANIK KÜMELER

2.3.2.1. TEMEL KAVRAMLAR

İki değerli mantıkla iki mutlak sonucu “0” ve “1” olarak, sonsuz değerli mantıkta sonuçları $[0,0, 1,0]$ aralığında tanımlayabileceğimizi belirtmiştik. Bu değerlere “*üyelik derecesi*” denir. “0” mutlak “yanlışlığı”, “1” ise mutlak “doğruluğu” gösterir. Bu üyelik derecesi daha önce bahsettiğimiz belirsizliği tanımlamaya çalışan bir fonksiyonla ölçülebilir.

Bu fonksiyon bir A Bulanık Kümesinin elamanlarını $[0,1]$ aralığındaki reel bir değere dönüştürür ve aşağıdaki şekilde gösterilir [26].

$$\mu_A(x) \in [0,1]$$

Tanım 4.1.

X boş olmayan bir küme olsun. X'deki bir Bulanık A kümesi üyelik fonksiyonu

$$A: X \rightarrow [0,1] \quad (4.1)$$

ile özelleştirilmiştir. $\forall x \in X$ için; x'in üyelik derecesi A(x) olarak yorumlanmıştır. (μ_A olarak da gösterilebilir)

Çalışılan X evreni kesin ve sınırlı olduğu zaman A kümesi sembolik olarak aşağıdaki gibi gösterilir:

$$A = \left\{ \frac{\mu A(x_1)}{x_1} + \frac{\mu A(x_2)}{x_2} + \dots \dots \dots \right\} = \left\{ \sum_i \frac{\mu A(x_i)}{x_i} \right\} \quad (4.2)$$

$i=(1,..)$


X evreni sürekli ve sınırsız ise A kümesi

$$A: \left\{ \int \frac{\mu A(x)}{x} \right\} \quad (4.3)$$

ile gösterilir. Bu gösterimdeki cebirsel semboller cebirsel anlamlarıyla kullanılmazlar. Örneğin “+” toplam anlamında değil teorik olarak birleşme anlamındadır. örneklerle yaklaşırsak;

Örnek 4.1.

Çoğu zaman sınırları kesin olarak belirleyemediğimiz durumlar ortaya çıkabilir. “1'e yaklaşan” real sayıların bulanık kümesinin üyelik fonksiyonunu aşağıdaki gibi tanımlanabilir:



Şekil 2.3.2. “1'e yaklaşan sayıların üyelik fonksiyonu”

Yukardaki önerme için uygun fonksiyonlardan biri Gaussian eğrisidir.

$\mu_{a,m}(x) = e^{-a(x-m)^2}$ $a>0, m \in \mathbb{R}$. Bu örnekte $m=1$ dir.

Eğer özel olarak “1’ yaklaşan doğal sayılar” için bir küme tanımlamak istersek, bunu aşağıdaki şekilde ifade edebiliriz

$$A = \{ 0.0/-2 + 0.3/-1 + 0.6 /0 + 1.0/1 + 0.6/2 + 0.3/3 + 0.0/4 \}$$

Not 1: Reel sayıların kümesi *sürekli* iken doğal sayıların kümesi *kesikli* olmaktadır.

Not 2: Bu örnekte Gaussian eğrisi keyfi olarak seçilmiştir. Örneğe uygun başka bir fonksiyonda seçilebilirdi. Fonksiyon şu koşulları sağlamalıdır:

- fonksiyon $x=1$ ’e göre simetrik olmalıdır.
- $A(1)=1$ ve diğer tüm $x \in X$ için $A(x) < 1$
- $A(x)$ 1’den 0’a $|x-1|$ artan farkı ile monoton olarak azalmalıdır.


Açıkça görülmektedir ki bulanık kümelerin kullanışlılığı büyük oranda bizim, farklı kavramlara uygun üyelik derecesi fonksiyonlarını oluşturabilme becerimize dayanmaktadır. Bu beceri, bulanık kümeler teorisinin ilk zamanlarında zayıf olsada, günümüzde birçok alanda gelişmiştir. En sık kullanılan fonksiyonlar kolaylık açısından “üçgen” ve “yamuktur”.

Örnek 4.2.

x bir sabit disk’in bir dakikadaki dönme hızı olsun. x hiçbir zaman çok hassas bir şekilde ölçülemeyeceği için bu durumda şu önermeyi yapmak daha gerçekçi olur:

“Dönme hızı nerdeyse tam olarak x ’e eşittir.” (4.4)

Eğer sabit diskin işlevi hakkında istatistiksel veriler mevcutsa, olasılık teorisi yaklaşımları ile bilinen hata hesaplamaları kullanılarak (4.4) önermesi modellenmelidir. Eğer böyle bir veri yoksa yada yeterince hassas değilse bulanık kümelere geçilebilir çünkü bulanık kümeler genellikle uzmanlar tarafından sezgisel biçimde belirlenebilir.



Şekil 2.3.3 Bir sabit diskin dönme hızını belirten μ bulanık kümesi

Uzmanın Şekil 2.3.3'teki μ bulanık kümesini seçtiğini varsayalım. Bu durumda dönme hızının a 'dan küçük ve d 'den büyük olamayacağı ve b ile c arasında herhangi bir değer almasının nerdeyse kesin olacağı düşünülmüştür. Bu nedenle $[a,d]$ aralığı kümenin *desteği* (*support*) ve $[b,c]$ aralığıda *özü* (*core*) olarak adlandırılır [26].

Tanım 4.2. (destek):

A X 'in bir bulanık kümesi olsun. A 'nın desteği, $\text{supp}(A)$, X 'in elemanları sıfır olmayan bir alt kümesidir.

$$\text{Supp}(A) : \{x \in X, A(x) > 0\} \quad (4.5)$$

Tanım 4.3. (normal bulanık küme):

Eğer herhangi bir $x \in X$ için $A(x)=1$ oluyorsa A bulanık kümesine *normal* denir. Aksi halde *subnormal*'dir.

Tanım 4.4. (bulanık kümenin yüksekliği):

A bulanık kümesinin en büyük üyelik derecesine o kümenin yüksekliği denir.

$$h(A) = \sup_{x \in X} A(x) \quad (4.6)$$

Tanım 4.5. (α -kesiti):

X de tanımlı bir A bulanık kümesi ve $\alpha \in [0,1]$ verilsin. α -kesiti, ${}^\alpha A$, ve güçlü α -kesit, ${}^{\alpha+} A$, aşağıdaki gibi tanımlanmış keskin kümelerdir:

$${}^{\alpha}\mathbf{A} = \{ x \mid A(x) \geq \alpha \} \quad (4.7)$$

$${}^{\alpha+}\mathbf{A} = \{ x \mid A(x) > \alpha \} \quad (4.8)$$

α -kesitleri ile ilgili bir örnek aşağıda incelenmiştir.


Örnek 4.3.

Genç, orta yaşlı ve yaşlı insan kavramını temsil eden $[0,80]$ aralığında tanımlı üç bulanık küme göz önüne alalım: sırasıyla A_1 , A_2 ve A_3 .

$$A_1(x) = \begin{cases} 1 & x \leq 20 \\ (35-x)/15 & 20 < x < 35 \\ 0 & x \geq 35 \end{cases}$$

$$A_2(x) = \begin{cases} 0 & x \leq 20 \text{ veya } x \geq 60 \\ (x-20)/15 & 20 < x < 35 \\ (60-x)/15 & 45 < x < 60 \\ 1 & 35 \leq x \leq 45 \end{cases}$$

$$A_3(x) = \begin{cases} 1 & x \geq 60 \\ (x-45)/15 & 45 < x < 60 \\ 0 & x \leq 45 \end{cases}$$



Şekil 2.3.4 Genç, orta yaşlı ve yaşlı kavramlarını temsil eden üyelik fonksiyonları.

2.3.2.2. BULANIK SAYILAR

Çoğu durumda sayısal bilgiler hassas bir şekilde tanımlanamaz. Örneğin “yaklaşık 45”, “0’a yakın”, “1000’den büyük” gibi ifadeler kullanılır. Bunlar *bulanık sayılara* birer örnektir. Bulanık alt- kümeler teorisini kullanarak bulanık sayıları reel sayılar kümesinin bir bulanık alt-kümesi olarak tanımlayabiliriz [26].

Eğer bulanık sayı aşağıdaki koşulları sağlıyorsa *quazi bulanık sayısı* olarak adlandırılır:

$$\lim_{t \rightarrow \infty} A(t) = 0 \quad \lim_{t \rightarrow -\infty} A(t) = 0 \quad (4.9)$$

Tanım 4.6. (üçgen bulanık sayı):

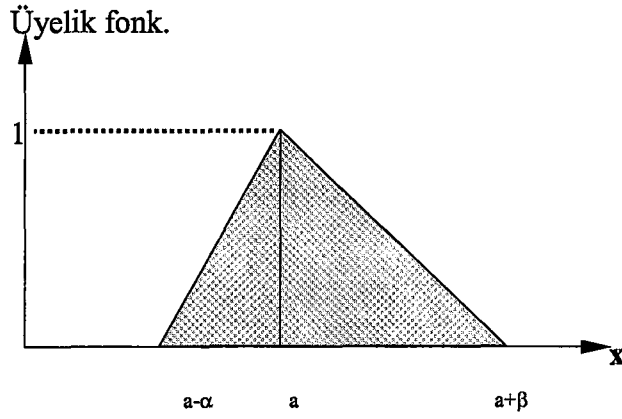
Bir A bulanık kümesinin merkezi a , sağ ve sol açıklığı sırasıyla $\gamma > 0$ ve $\beta > 0$ ve üyelik fonksiyonu aşağıdaki gibi veriliyorsa A kümesine *üçgen bulanık sayı* denir:

$$A(t) = \begin{cases} 1 - (a-t) / \gamma & \text{eğer } a - \gamma \leq t < a \\ 1 - (t-a) / \beta & \text{eğer } a \leq t < a + \beta \\ 0 & \text{diğer durumlar} \end{cases}$$

$A = (a, \gamma, \beta)$ notasyonu ile gösterilir.

$${}^\alpha A = [a - (1-\gamma)\alpha, a + (1-\gamma)\beta] ; \text{ tüm } \gamma \in [0,1] \quad (4.10)$$

Önermesinin doğruluğu da kolayca görülebilir.



Şekil 2.3.5 Üçgen bulanık sayı (triangular fuzzy number)


a merkezli üçgen bulanık sayı şu şekilde yorumlanabilir
 “ x yaklaşık olarak a 'ya eşittir.”

Tanım 4.7. (yamuk bulanık sayı):

Bir A bulanık kümesinin tolerans aralığı $[a, b]$, sağ ve sol açıklığı sırasıyla $\gamma > 0$ ve $\beta > 0$ ve üyelik fonksiyonu aşağıdaki gibi veriliyorsa A kümesine *yamuk bulanık sayı* denir:

$$A(t) = \begin{cases} 1 - (a-t) / \gamma & \text{eğer } a - \gamma \leq t < a \\ 1 & \text{eğer } a \leq t \leq b \\ 1 - (t-b) / \beta & \text{eğer } b \leq t < b + \beta \\ 0 & \text{diğer durumlar} \end{cases} \quad (4.11)$$

$A = (a, b, \gamma, \beta)$ notasyonu ile gösterilir. ${}^\alpha A = [a - (1-\gamma)\alpha, a + (1-\gamma)\beta]$; tüm $\gamma \in [0, 1]$ önermesinin doğruluğu da kolayca görülebilir.



Şekil 2.3.6 Yamuk bulanık sayı


Yamuk bir bulanık sayı şu şekilde yorumlanabilir:

“x yaklaşık olarak [a,b] aralığındadır .”

Tanım 4.8. (altküme):

A ve B X evreninde tanımlanmış iki bulanık küme olsun. Aşağıdaki koşul sağlanıyorsa A, B'nin alt-kümesidir denir:

$$A(t) \leq B(t) \quad \text{tüm } t \in X \text{ için}$$



Şekil 2.3.7 A, B'nin alt-kümesidir.

Örnek 4.4.

A ve B X evreninde tanımlı iki bulanık küme olsun.

$$X = \{ 1, 5, 10, 15, 20 \}$$


$$A = \{ 0.0/1 + 0.2/5 + 0.4/10 + 1/15 + 0.6/20 \}$$

$$B = \{ 0.1/1 + 0.3/5 + 0.5/10 + 1/15 + 0.7/20 \}$$


A \subset B olduğu görülmektedir.

Bazı üyelik fonksiyonları aşağıda gösterilmiştir.


$$\text{Üçgen: } \mu(x) = \begin{cases} 0, & c < x < a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \end{cases}$$




$$\text{Yamuk: } \mu(x) = \begin{cases} 0, & d < x < a \\ 1, & b \leq x \leq c \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{d-x}{d-c}, & c \leq x \leq d \end{cases}$$



$$\text{Tekil (singleton): } \mu(x) = \begin{cases} 0, & x \neq b \\ 1, & x = b \end{cases}$$



$$\text{Gaussian: } \mu(x) = e^{-\frac{(x-c)^2}{2\sigma^2}}$$



Şekil 2.3.8 Bazı Üyelik Fonksiyonları

2.3.2.3. BULANIK KÜME İŞLEMLERİ

Boş olmayan bir X evreninde A ve B bulanık kümeleri tanımlanmış olsun. A ve B kümeleri için birleşme, arakesit ve tümleyen teorik küme işlemleri sırasıyla aşağıdaki gibi verilmiştir [26].

$$(A \cup B)(t) = \max[A(t), B(t)] = A(t) \vee B(t)$$

$$(A \cap B)(t) = \min[A(t), B(t)] = A(t) \wedge B(t) \quad (4.12)$$

$$\neg A(t) = 1 - A(t)$$


Örnek 4.5.

$$X = \{-2, -1, 0, 1, 2, 3, 4\}$$

$$A = \{0.6/-2 + 0.3/-1 + 0.6/0 + 1.0/1 + 0.6/2 + 0.3/3 + 0.0/4\}$$

$$B = \{0.1/-2 + 0.3/-1 + 0.9/0 + 1.0/1 + 0.9/2 + 0.3/3 + 0.2/4\}$$

$$A \cup B = 0.6/-2 + 0.3/-1 + 0.9/0 + 1.0/1 + 0.9/2 + 0.3/3 + 0.2/4 \}$$



Şekil 2.3.9 A ve B üçgen bulanık sayıların birleşimi


Örnek 4.6.

$$X = \{-2, -1, 0, 1, 2, 3, 4\}$$

$$A = \{0.6/-2 + 0.3/-1 + 0.6/0 + 1.0/1 + 0.6/2 + 0.3/3 + 0.0/4\}$$

$$B = \{0.1/-2 + 0.3/-1 + 0.9/0 + 1.0/1 + 0.9/2 + 0.3/3 + 0.2/4\}$$

$$A \cap B = 0.1/-2 + 0.3/-1 + 0.6/0 + 1.0/1 + 0.6/2 + 0.3/3 + 0.0/4 \}$$



Şekil 2.3.10 A ve B üçgen bulanık sayılarının kesişimi, μ Üyelik fonksiyonu.

Örnek4.7.


$$X = \{-2, -1, 0, 1, 2, 3, 4\}$$

$$A = \{0.6/-2 + 0.3/-1 + 0.6/0 + 1.0/1 + 0.6/2 + 0.3/3 + 0.0/4\}$$

$$B = \{0.1/-2 + 0.3/-1 + 0.9/0 + 1.0/1 + 0.9/2 + 0.3/3 + 0.2/4\}$$

$$\neg A = \{0.4/-2 + 0.7/-1 + 0.4/0 + 0.0/1 + 0.4/2 + 0.7/3 + 1.0/4\}$$

$$\neg B = \{0.9/-2 + 0.7/-1 + 0.1/0 + 0.0/1 + 0.1/2 + 0.7/3 + 0.8/4\}$$



Şekil 2.3.11 A bulanık kümesinin tümleyeni

Keskin Kümeler için bilinen tüm işlemler aşağıdaki iki durum haricinde bulanık kümeler içinde geçerlidir:

$$1. A \cup \neg A = X \quad \text{ve} \quad 2. A \cap \neg A = \emptyset \quad (4.13)$$

Bu iki durum bulanık kümeler için geçerli değildir.

- $A \cup \neg A \neq X$. tüm $t \in X$ için $A(t) = 1/2$ olsun.

$$(\neg A \vee A)(t) = \max(\neg A, A) = \max(1-1/2, 1/2) = 1/2$$

$$1/2 \neq 1$$

- $A \cap \neg A \neq X$. tüm $t \in X$ için $A(t) = 1/2$ olsun.

$$(\neg A \wedge A)(t) = \min(\neg A, A) = \min(1-1/2, 1/2) = 1/2$$

$$1/2 \neq 0$$

Buna karşın De Morgan kuralları bulanık mantık için de geçerlidir.

$$\neg(A \wedge B) = \neg A \vee \neg B \quad \neg(A \vee B) = \neg A \wedge \neg B \quad (4.14)$$

2.3.3. T-NORM VE T-KONORM OPERATÖRLERİ

A ve B gibi iki bulanık kümenin kesişimi genellikle $T:[0,1] \times [0,1] \rightarrow [0,1]$ fonksiyonu tarafından tanımlanır.

$$\mu_{A \cap B}(x) = T(\mu_A(x), \mu_B(x)) \quad (4.15)$$

Burada T fonksiyonu bulanık kesişim operatörü (klasik mantıkta VE işlemi) olup T-Norm (Triangular Norm) olarak bilinir.

2.3.3.1. TANIM: T-NORM

T-Norm Operatörleri bulanık küme kesişim operatörleri olup aşağıdaki özellikleri sağlarlar.

$$\mu_{A \cap B}(x) = T(\mu_A(x), \mu_B(x)) \quad (4.16)$$

Özellikler:

1. $T(0,0)=0$, $T(a,1)=T(1,a)$ Sınır Özelliği
2. Eğer $a \leq c$ ve $b \leq d$ ise $T(a,b) \leq T(c,d)$ Monotonluk Özelliği
3. $T(a,b) = T(b,a)$ Değişme Özelliği
4. $T(a,T(b,c)) = T(T(a,b),c)$ Birleşme Özelliği

En çok kullanılan dört T-Norm operatörleri aşağıdadır.

Minimum	$T_1(a,b)=\min(a,b)$
Cebirsel Çarpım	$T_2(a,b)=a.b$
Sınırlı Çarpım	$T_3(a,b)=\max(0,a+b-1)$
Drastik Çarpım	$T_4(a,b)= \begin{cases} a & b=1 \text{ ise} \\ b & a=1 \text{ ise} \\ 0 & a,b<1 \text{ ise} \end{cases}$

Bu operatörler sıralanırsa ;

$$T_4(a,b) \leq T_3(a,b) \leq T_2(a,b) \leq T_1(a,b)$$

2.3.3.2. TANIM: T-KONORM (S_NORM)

T-Konorm Operatörleri, bulanık küme bileşke operatörleri (klasik mantıkta VEYA işlemi) aşağıdaki özellikleri sağlar.

$$\mu_{A \cup B}(x) = S(\mu_A(x), \mu_B(x))$$

Özellikler:

1. $S(1,1)=1$, $S(0,a)=S(a,0)$ Sınır Özelliği
2. Eğer $a \leq c$ ve $b \leq d$ ise $S(a,b) \leq S(c,d)$ Monotonluk Özelliği
3. $S(a,b) = S(b,a)$ Değişme Özelliği
4. $S(a,S(b,c)) = S(S(a,b),c)$ Birleşme Özelliği

En çok kullanılan dört T-Konorm operatörleri aşağıdadır.

Maksimum	$S_1(a,b)=\max(a,b)$
Cebirsel Toplam	$S_2(a,b)=a+b-ab$
Sınırlı Toplam	$S_3(a,b)=\min(1,a+b)$
Drastik Toplam	$S_4(a,b)= \begin{cases} a & b=0 \text{ ise} \\ b & a=0 \text{ ise} \\ 1 & a,b>0 \text{ ise} \end{cases}$

Bu operatörler sıralanırsa ;

$$S_1(a,b) \leq S_2(a,b) \leq S_3(a,b) \leq S_4(a,b)$$

2.3.3.3. TEOREM: GENELLEŞTİRİLMİŞ DEMORGAN KURALLARI

T-Norm ve T-Konorm operatörleri birbirinin duali olup genelleştirilmiş DeMorgan Kurallarını sağlarlar. [21]

$$a.b = \overline{\overline{a+b}} \rightarrow T(a,b) = N(S(N(a),N(b))) \quad (4.17)$$

$$a+b = \overline{\overline{a.b}} \rightarrow S(a,b) = N(T(N(a),N(b))) \quad (4.18)$$

$N(.)$ burada bulanık tümleyen operatörüdür.

Örnek4.8.

Sınırlı Toplam $S(a,b) = \min(1, a+b)$ olduğuna göre sınırlı çarpımın $T(a,b) = \max(0, a+b-1)$ olduğunu gösterelim.

$$\max(1-a, 1-b) = 1 - \min(a, b) \quad , \quad 0 \leq a, b \leq 1$$

$$\min(1-a, 1-b) = 1 - \max(a, b) \quad , \quad 0 \leq a, b \leq 1$$

$$T(a,b) = N(S(N(a), N(b))) \quad \text{ve} \quad N(a) = 1-a$$

$$= 1 - S(1-a, 1-b) \quad \text{ve} \quad S(a,b) = \min(1, a+b)$$

$$= 1 - \min(1, 1-a+1-b)$$

$$T(a,b) = \max(0, a+b-1)$$

2.3.4. BULANIK EĞER - ÖYLEYSE KURALLARI

Bulanık bir eğer-öyleyse kuralı genel olarak Eğer x , A ise Öyleyse y de B dir. Burada , A ve B birer sözel değişken olabilir (Linguistic) .

“Eğer x A ise” kısmı Kabul. “ Öyleyse y de B dir” kısmı ise karar dır.

Bazı örneklerle anlatırsak;

2023 TÜRKİYE KÜLTÜR VE TURİZM BAKANLIĞI
CERAMİK SANAYİCİLERİ VE İHRACATÇILARI BİRLİĞİ

- Eğer hız yüksek ise Öyleyse vitesi yükselt.
- Eğer zemin ıslak ise Öyleyse yol kaygandır.
- Eğer yolcu sayısı fazla ise Öyleyse otobüs kalabalıktır.

“Eğer x , A ise Öyleyse y de B dir” ifadesinde A kümesinden B kümesine tanımlı R bulanık bağıntısı $A \times B$ kartezyen çarpım kümesinde tanımlı olup $A \rightarrow B$ ile gösterilir. Bulanık Eğer - Öyleyse kurallarına ilişkin R bulanık bağıntısı, $A \times B$ üzerinde tanımlı olmasından dolayı bir T-Norm operatörü yardımı ile bulunur.

$R: A \rightarrow B$

Eğer x , A ise Öyleyse y de B dir

$$\mu_R(x,y) = T[\mu_A(x), \mu_B(y)]$$

T-Norm Operatörü minimum operatörü ise ;

$$\mu_R(x,y) = \min[\mu_A(x), \mu_B(y)]$$

T-Norm Operatörü cebirsel çarpım operatörü ise ;

$$\mu_R(x,y) = \mu_A(x) \cdot \mu_B(y)$$


T-Norm Operatörü sınırlı çarpım ise ;

$$\mu_R(x,y) = \max[0, \mu_A(x) + \mu_B(y) - 1] \quad (4.19)$$

2.3.5. DURULAŞTIRMA YÖNTEMLERİ

Bulanık Mantık işlemlerinden sonra son elde ettiğimiz değer bir bulanık değer olduğundan bunun bir duru değere çevrilmesi gerekmektedir.

En çok kullanılan 5 çeşit durulaştırma metodu şunlardır [20].



Şekil 2.3.12 Bulanık değerlerden elde edilecek duru değerler.

2.3.5.1 AĞIRLIK MERKEZİ METODU

Bu metotta , yukardaki gibi elde edilen Karar a ait bulanık kümenin ağırlık merkezi bulunarak duru bir karar değeri elde edilir.

$$\psi = \frac{\int z \cdot \mu(z) dz}{\int \mu(z) dz} \quad (4.20)$$

2.3.5.2. EŞİT ALAN METODU

Bu metotta, duru karar olarak , alanı iki eşit parçaya ayıran $z=\phi$ değeri esas alınır.

$$\int_a^{\phi} \mu(z) dz = \int_{\phi}^{\beta} \mu(z) dz \quad (4.21)$$

2.3.5.3. EN KÜÇÜK MAKSİMUM METODU

Bu metotta , üyelik değerleri maksimum olan noktaların en küçüğü esas alınır.

Yukarıdaki şekilde $z=\alpha$ dır.

2.3.5.4. EN BÜYÜK MAKSİMUM METODU

Bu methoda , üyelik değerleri maksimum olan noktaların en büyüğü esas alınır.

Yukarıdaki şekilde $z=\beta$ dır.

2.3.5.5. MAKSİMUMLARIN ORTALAMASI METODU

Bu methoda , üyelik değerleri maksimum olan noktaların ortalaması esas alınır.

Yukarıdaki şekilde $z=(\alpha+\beta)/2$ dir.

2.3.6. BULANIK KIYASLAMA VE SUGENO YAKLAŞIMI

Genel olarak bulanık sistemler iki grupta incelenir. Bunlar Mamdani yaklaşımı ve Sugeno yaklaşımıdır [22]. Biz bu tezde Bulanık-Yapay Sinir Ağlarıyla (BYSA) uygulama yapacağımız için BYSA uygulamalarında kullanılabilen Sugeno yaklaşımından bahsedeceğiz.

Takagi ve Sugeno tarafından geliştirilen bu sistemde veri tabanındaki girdiler birer sayı , bulanık kural ve çıkarım motorunun çalışması sonunda elde edilen çıktılar ise girdilerin bir fonksiyonu şeklindedir. Yani Kural tabanındaki öncül kısımların değişkenleri olduğu gibi , ise öyleyse kelimesinden sonraki kural soncul kısmına bu değişkenlerin birer doğrusal fonksiyonu olarak yansıtıldığı düşünülmüştür.

Buna göre, kural

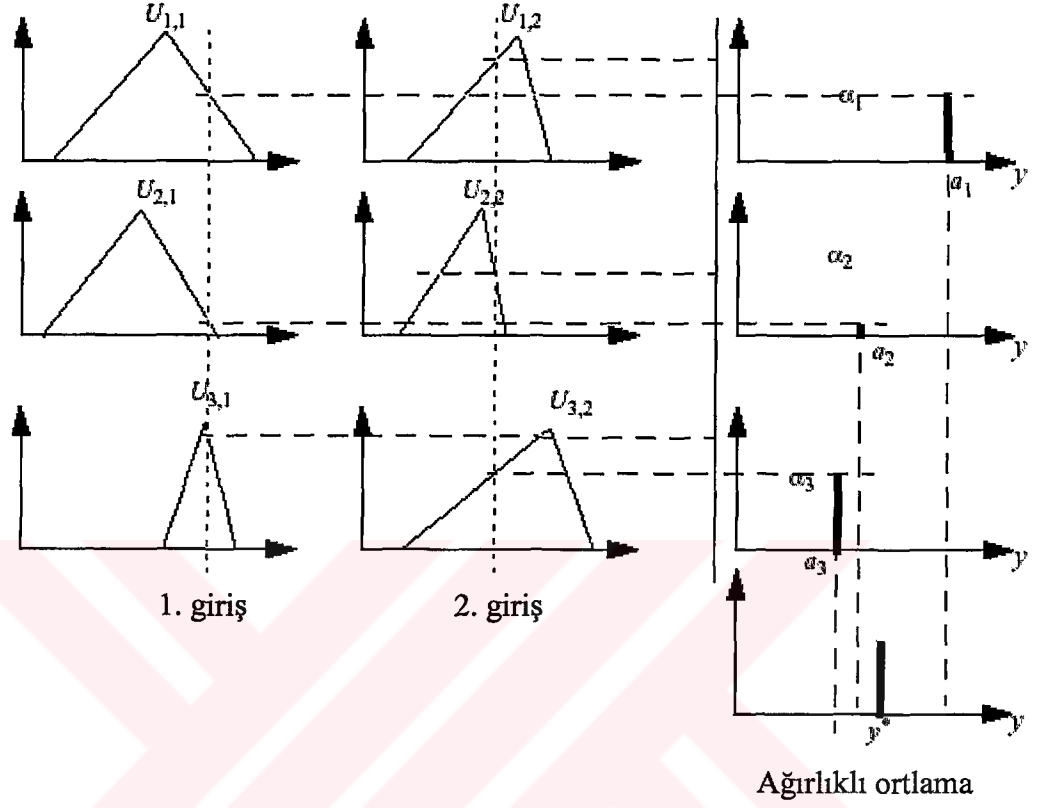
Eğer arabanın hızı x yüksek ise y , $y=ax$

şeklinde ifade edilebilir. Mesela, 3 tane öncül değişkenin (x_1, x_2, x_3) bulunması halinde soncul değişken olan y genel olarak bulanık sistemin kurallarından birinde

Eğer x_1 az ve x_2 yüksek ve x_3 geniş İse $y=a_0+a_1x_1+a_2x_2+a_3x_3$

şeklinde ifade edilebilir. Bu kuralların soncul kısımları sanki çok terimli bir doğrusal denklemden oluşmuştur.

Sugeno yaklaşımına ait bi örnek aşağıda Şekil 2.3.13 te gösterilmiştir.



Şekil 2.3.13 Sugeno modeli..

Eğer 1. giriş = $U_{1,1}$ VE 2. giriş = $U_{1,2}$ İSE $y=a_1$

Eğer 1. giriş = $U_{2,1}$ VE 2. giriş = $U_{2,2}$ İSE $y=a_2$

Eğer 1. giriş = $U_{3,1}$ VE 2. giriş = $U_{3,2}$ İSE $y=a_3$

2.4. BULANIK-YAPAY SINİR AĞLARI

Bu bölümde Bulanık–Yapay Sinir Ağlarından (Neuro-Fuzzy) bahsedilmiştir. BYSA , YSA nın ve Bulanık Mantığın birleştirilmesiyle oluşmuştur. Bulanık mantık ve YSA olarak iki kısımda incelenir. Burada kullanılacak olan model Uyarlanabilir Bulanık–Yapay Sinir Ağları, diğer bir deyişle Adaptive Neuro-Fuzzy Inference Systems (ANFIS) metodudur [23]. Modern Neuro-Fuzzy sistemler özel bir çok katmalı ileri beslemeli yapay sinir ağı biçimindedir. BYSA bu yapılar içinde en yaygın kullanılanıdır. BYSA sisteminde bağlantı katsayıları, ileri besleme değerlerinin yayılma biçimi ve aktivasyon fonksiyonları geleneksel yapay sinir ağlarından oldukça farklıdır. Bu aşamalar, BYSA’da üyelik fonksiyonları, kurallar, kuralların etki kuvveti gibi bulanık mantık sistemlerinin bileşenlerinden oluşur. Bir BYSA çok çeşitli farklı yaklaşımı ifade edebiliyor olsa da özellikle aşağıdaki özellikleri göstermesi beklenir.

- BYSA, yapay sinir ağları teorisinden türetilmiş belirli bir öğrenme algoritmasıyla eğitilebilen bulanık mantık sistemine dayanır. Öğrenme prosedürü yerel enformasyon üzerinde çalışır ve ilgili bulanık sistemde sadece yerel değişiklikler yapar.
- Bir BYSA sistemi üç katmanlı ileri beslemeli yapay sinir ağı olarak görülebilir. İlk katman giriş değişkenlerini ifade eder, orta katman bulanık mantık kurallarını içerir ve üçüncü katman çıkış değişkenleridir. Bu yaklaşımla bulanık mantık üyelik kümeleri bağlantı katsayıları olarak düşünülebilir. Hatta bir BYSA sistemini bu şekilde ifade etmek için öğrenme algoritması kullanacak olmak şart değildir. Ancak, çalışma değerlerinin eğitim ile giriş çıkış ilişkilerinden öğrenilmesi uygulamada önemli kolaylıklar sağlar. BYSA ların beş katman olarak düşünüldüğü mimarilerde, bulanık üyelik fonksiyonları, ağırlık katsayıları olarak değerlendirilmek yerine sistemin ikinci ve dördüncü katmanı olarak görülür.
- Bir BYSA başlangıç, eğitim ve eğitim sonrası aşamaların tümünde bulanık kurallar sistemi olarak görülmelidir. Sistemdeki kurallar

istenirse sadece eğitim verilerin dayalı olarak belirlenir ya da bulanık mantık kurallarının öngörülebilirliğine göre sistemi tarif eden kişi tarafından şart koşulur.

- İstenirse, bulanık mantık sisteminde kullanılan öğrenme yordamı ilgilendiği sistemin mantıksal anlamını da göz önünde bulunduracak şekilde uyarlanabilir.
- Bir BYSA n parametrelili bir fonksiyonun kestirimini o fonksiyonu kısmen tanımlayan eğitim kümesinden yapmaya çalışır.

BYSA da üyelik fonksiyonlarının parametreleri, giriş çıkış eğitim çiftlerinin değerlerine göre geriyayılım algoritması ya da en küçük kareler yöntemiyle ayarlanabilir. Ancak BYSA'nın bu uyarlamalı yapısı geleneksel bulanık mantık sistemlerinden farklı olarak tasarım serbestliğine bir takım kısıtlamalar getirir.


BYSA sıfırcı yada birinci dereceden Sugeno modeli sistemleriyle tanımlanır. BYSA'dan Tekil (Single) çıkış elde edilir. Sugeno modelindeki bulanık sistemlerin çıkış üyelik fonksiyonları diğer bulanık mantık sistemlerinden farklı olarak ya bir sabit fonksiyon ya da doğrusal bir fonksiyon olmalıdır. BYSA'nın çıkışı bu fonksiyonun aldığı değerdir.

2.4.1. BYSA YAPISI

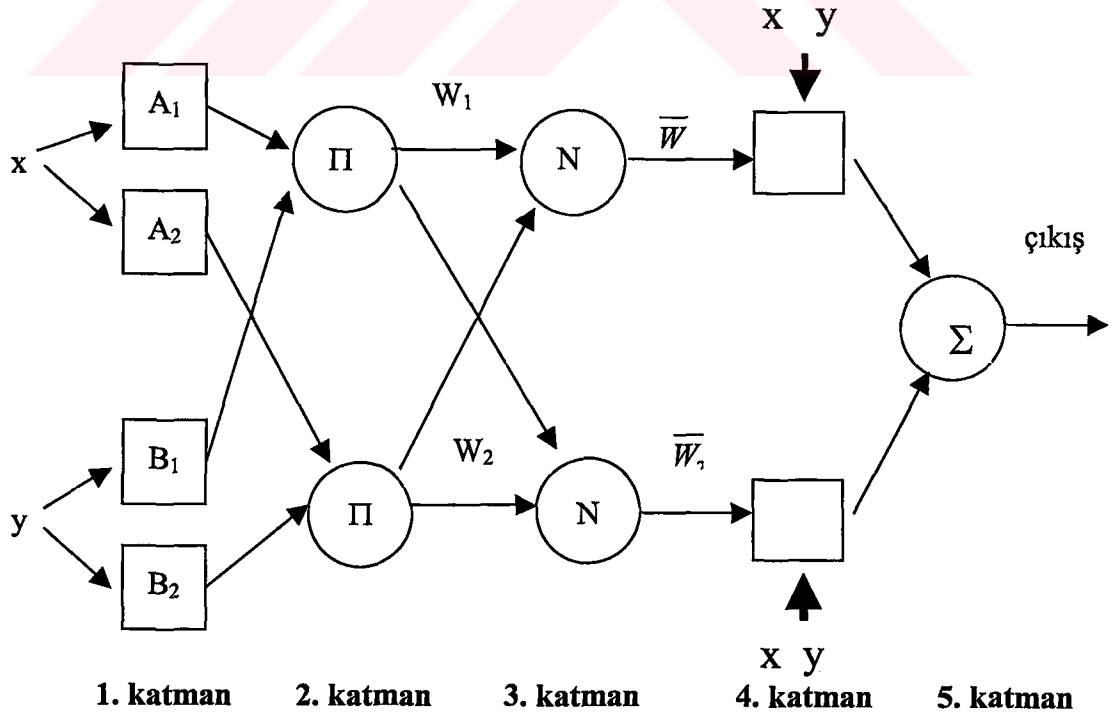
Burada girişlerimiz x ve y çıkışımız ise z olsun. Sıfırcı dereceden bir sugeno Fuzzy metodunda $f_1 = k_1$ ve $f_2 = k_2$ gibi bir sabittir. Birinci dereceden Sugeno Fuzzy metodunda ise $f_1 = p_1x + q_1y + r_1$ ve $f_2 = p_2x + q_2y + r_2$ dir [23].

$$\begin{array}{ll} \text{Kural 1} & \text{Eğer } x \text{ } A_1 \text{ ve } y \text{ } B_1 \text{ ise } f_1 = p_1x + q_1y + r_1 \\ \text{Kural 2} & \text{Eğer } x \text{ } A_2 \text{ ve } y \text{ } B_2 \text{ ise } f_2 = p_2x + q_2y + r_2 \end{array} \quad (5.22)$$

Şekil 2.4.1 de iki kurallı , iki girişli birinci dereceden sugeno bulanık modeli gösterilmiştir. Şekil 2.4.2 de ise buna eşdeğer olan BYSA mimarisi gösterilmiştir.



Şekil 2.4.1 iki kurallı , iki girişli birinci dereceden sugeno bulanık modeli



Şekil 2.4.2 BYSA yapısı

Şekil 2.4.2 de BYSA yapısı gösterilmektedir. Burada aynı katmandaki her düğüm benzer davranış göstermektedir.

Bu yapı beş katmandan oluşmaktadır.

1. Katman :

Burada aynı katmandaki her düğüm benzer davranış gösterir.

$$O_{1,1} = \mu A_1(x)$$

$$O_{1,2} = \mu A_2(x)$$

$$O_{1,3} = \mu B_1(y)$$

$$O_{1,4} = \mu B_2(y) \quad (5.23)$$

Burada x ve y girişler, A_i ve B_i ise dilsel (linguistic) terimlerdir. (hızlı veya yavaş gibi..) Bu durumda O_i , A_i ve B_i nin üyelik fonksiyonları derecesi olmaktadır.

Burada A veya B herhangi bir üyelik fonksiyonu olabilir.

Örnek olarak Gauss fonksiyonu aşağıda verilmiştir.

$$\mu A(x) = e^{-\frac{1}{2} \left(\frac{x-c}{\sigma} \right)^2} \quad (5.24)$$

Burada $\mu A(x)$ üyelik fonksiyonu, c ve σ ise öncü parametrelerdir.

2. Katman :

Bu katmandaki her düğüm Π ile tanımlanmıştır. Burada her bir düğümdeki çıkış giren sinyallerin çarpımıdır (product).

$$O_{2i} = W_i = \mu A_i(x) \cdot \mu B_i(y), \quad i = 1,2 \quad (5.25)$$

Burada T-Norm operatörleri ya da Bulanık AND kullanılabilir.

3. Katman

Bu katmandaki her düğüm N ile tanımlanmıştır. Burada W lar normalize edilmektedir.

$$O_{3i} = \bar{W}_i = \frac{W_i}{W_1 + W_2}, \quad .i = 1,2 \quad (5.26)$$

\bar{W}_i burada normalize edilmiş etki kuvvetidir.

4. Katman

Burada her düğüm, düğüm fonksiyonuyla uyarlanabilir .

$$O_{4i} = \bar{W}_i . f_i = \bar{W}_i (f_i = p_i x + q_i y + r_i) \quad (5.27)$$

Burada \bar{W}_i 3. katmanda normalize edilmiş etki kuvveti , p_i , q_i , r_i ise karar (consequent parameters) parametreleridir.

5. Katman

Burada Σ ile gösterilen gelen tüm girişleri toplayan ve bir çıkışı olan tek bir düğüm söz konusudur.

$$\text{Tüm Çıkışlar} = O_{5i} = \sum_i \bar{W}_i f_i = \frac{\sum_i W_i f_i}{\sum_i W_i} \quad (5.28)$$

BYSA'nın kullanımına bir örnek vermek gerekirse:


Örnek 5.1.

Aşağıdaki şekilde ifade edilen iki boyutlu sinc denklemini modellemek istediğimizi düşünelim [23].

$$z = \text{sinc}(x, y) = \frac{\sin(x)\sin(y)}{xy}$$

çift olarak dağılmış bir seçim uzayında $[-10,10] \times [10,10]$ giriş aralığında denklemi kullanarak 121 tane eğitim verisi çifti elde edelim. Buradaki BYSA her iki giriş değişkenine ait dört üyelik fonksiyonu ile toplam 16 kural içerir. Ayar parametreleri

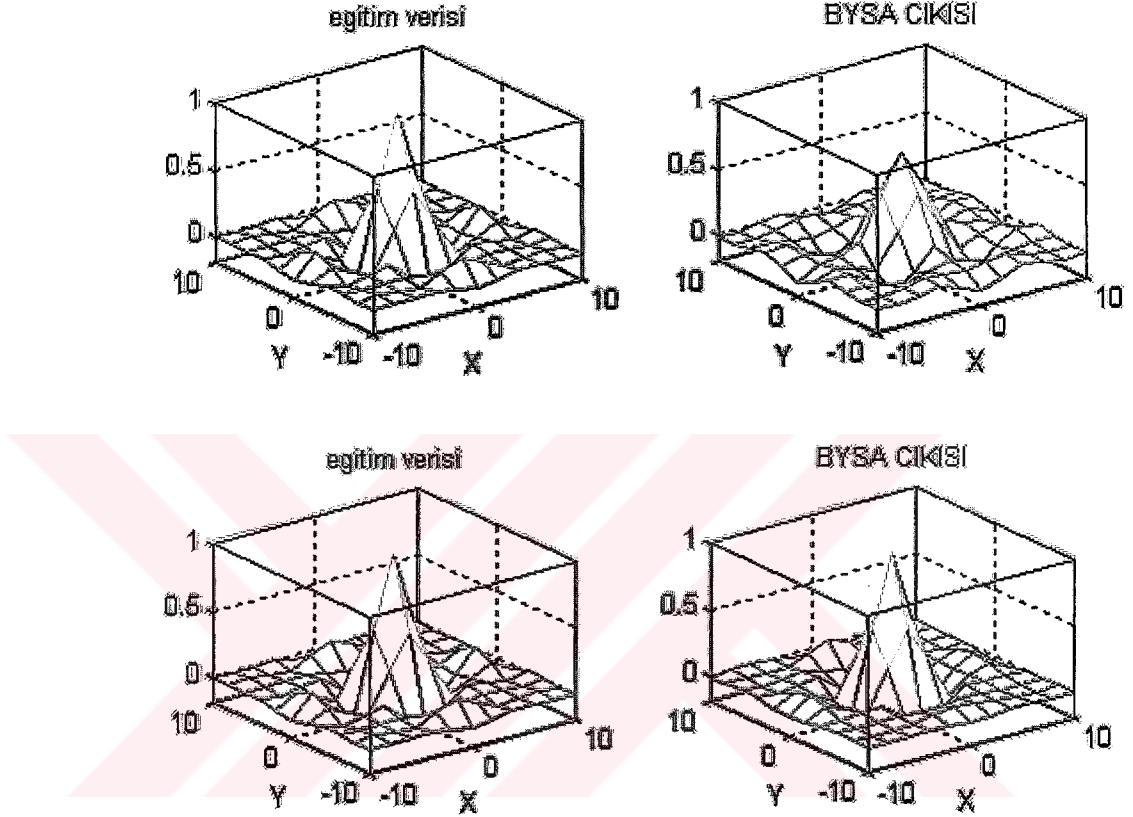
ise, 24 tane doğrusal olmayan temel parametre ve devamındaki 48 doğrusal olmayan parametre ile birlikte toplam 72 parametredir. (Dört kurallı ve dokuz kurallı BYSA'lar denendiğinde, bu modellerin doğrusal olmama düzeyi yüksek olan sinc fonksiyonuna yakınsama da başarısız olduğu görülmüştür).



Şekil 2.4.3 MLP ve BYSA için RMSE eğrileri

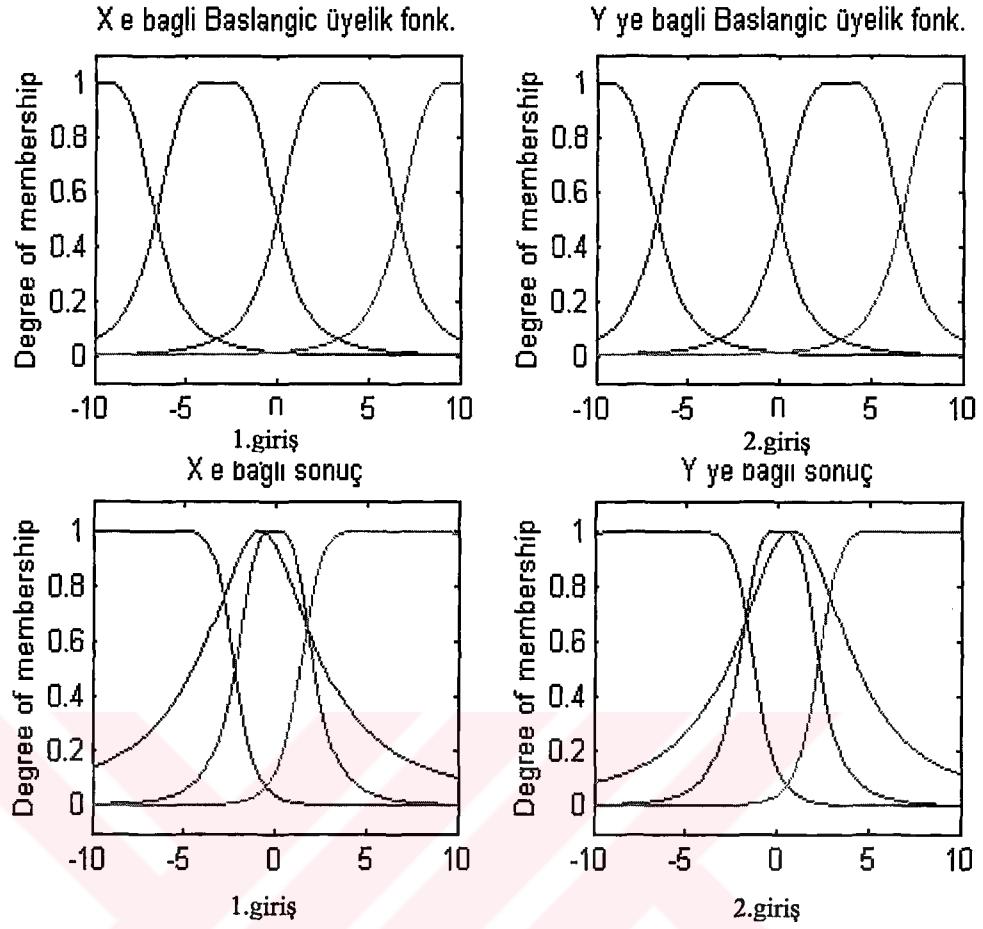
Şekil 2.4.3'te RMSE (hata karesinin kökleri ortalaması) eğrileri hem bir MLP (çok katmanlı perseptron) hem de tarif ettiğimiz BYSA modeli için elde edilmiştir. Her eğri 10 farklı denemede ki 10 hata eğrisinin ortalama sonucudur. MLP için bu 10 deneme farklı rasgele başlangıç katsayılarıyla çalışır. BYSA içinse bu 10 deneme 0.01 ile 0.10 arasında değişen 10 farklı k değeri için gerçekleştirilmiştir.

Ayar parametreleri 73 tane (bağlantı katsayıları ve eşik değerleri) olan geriyayılımlı MLP, hızlı yayılım algoritmasıyla eğitilmiştir ki bu yöntem geriyayılımlı MLP için en iyi öğrenme algoritması olarak gösterilir. Şekilde BYSA'nın doğrusal olmama düzeyi çok yüksek olan bir yüzeyi MLP'den daha verimli modelleyebildiği görülmektedir. Ayrıca vurgulanmalıdır ki, aynı sayıda eğitim çevrimi için (şekil hesaplanırken 250), hibrit öğrenme kuralı daha fazla işlem gerektirdiğinden BYSA daha uzun sürmemiştir. Eğitim çevrimi sayısı MLP için artırılrsa da performans 100 çevrimden sonra sabit hale gelmiştir. MLP'nin zayıf performansından kaynaklanıyor gibi görünmektedir; rasgele belirlenen başlangıç katsayıları nedeniyle öğrenme prosesi yerel minimumlara takılı kalır veya bazı nöronlar eğitim sırasında doyuma gider. Bu iki durumun her ikisi de MLP'nin yakınsama gücünü azaltır.



Şekil 2.4.4 Eğitim verisi (sol üst) ve BYSA'dan hesaplanan yüzeylerin 0.5 çevrimde (sağ üst), 99.5 çevrimde (sol alt) ve 249.5 çevrimde aldığı değer.

Eğitim verisi ve eğitim çevriminin çeşitli aşamalarında yeniden oluşturulmuş yüzeyler Şekil 2.4.4'te görülmektedir. Hata ölçümü her seferinde bir ileri geçiş tamamlandıktan sonra hesaplandığından (tam bir çevrimin ilk yarısı), şekilde gösterilen çevrim sayıları hep .5'li gösterilmiştir.



Şekil 2.4.5 Üyelik fonksiyonlarının başlangıç ve sonuçtaki durumu

Bir diğer şekil, (Şekil 2.4.5) ise başlangıç ve sonuç üyelik fonksiyonlarını göstermektedir. Eğitim veri yüzeyindeki keskin değişimlerin orijin etrafında artmasının üyelik fonksiyonunun orijine doğru çekilmesinden sorumlu olmasını gözlemiş olmak ilgi çekicidir. Teorik olarak x ve y'nin her ikisindeki sonuç üyelik fonksiyonlarının orijine göre simetrik olması beklenir. Ancak, sayısal hesaplamadaki kesme hatası ve en küçük kareler kestirimcisini başlatmak için yaklaşık olarak alınan başlangıç değerleri nedeniyle beklendiği gibi olmamıştır.

2.5. ESWL (EXTRACORPOREAL SHOCK WAVE LITHOTRIPSY) AYGITI VE GENEL BİLGİLER

Uzak Doğu Ülkelerinde bazı illüzyonistlerin elleri ile insan karnını açıp, hastalıklı organı çıkarıp sonra hiç iz bırakmadan kapattıkları yanılısaması 21.YY insanının bile dikkatini çekmektedir.

Ultrasonik uçakların camdan yapılı ön panellerinin düşen yağmur damlaları ile kırılabilmesi bilim adamlarının dikkatini çekmiş,Yapılan çalışmalarla''Ses dalgaları yeteri hız ve şiddette iseler katı cisimleri kırabilirler''sonucuna varılmıştır. Daha sonra %60'ı su olan vücudumuzun %10 kayıp ile bu ses dalgalarını ilettiği anlaşılmıştır.Bu sayede teknoloji tıbbi alanda uygulanabilir hale gelmiştir.

Ameliyat gerektiren bir hastalığın; Vücut bütünlüğünü bozmadan (kesmeden),genel anestezi kullanmadan tedavisi de insanlığın büyük ve en eski düşlerinden birisiydi. Yüksek Enerjili Ses Dalgalarının (YESD) üriner sistem taşlarının tedavisinde kullanılması bu rüyayı gerçek yapmıştır. Ürolojide kullanılan bu yenilik safra kesesi taşları,tükürük bezi taşları, romatizma hastalıkları, kırık iyileşimi vb. alanlarda başarı ile uygulanılmaktadır. Hatta çamaşırların deterjansız temizlemede 1999 yılından beri ABD de kullanılmaktadır. Zararlı etki ve atıkları içermemesi BLUE WAVE ULTRASON ismini almasına neden olmuştur. Günümüz teknolojilerinin bu övgüye layık olması nadir görülen bir olgudur.

Mulvoney 1953 yılında ilk kez ultrasonik dalgalar ile lithotripsi (taş kırma) yaptı. Yutkin 1955 yılında Kiev Üniv.de Elektro Hidrolik Lithotriptörü (EHL) keşfetti ve Yüksek Enerjili Ses Dalgaları(YESD) oluşturdu. Chaussy ise 1980 yılında ilk kez bir hastaya ESWL uyguladı [24].

2.5.1. ESWL NEDİR ?

“Extracorporeal Shock Wave Lithotripsy” olarak adlandırılan taş kırma işlemidir. Vücut dışında oluşturulan şok dalgalarının vücut içine yönlendirilerek taşa kadar ulaşması ve taşı kırması esasına dayanır. İlk olarak “Mulvaney” 1953 yılında ultrasonik dalgalar ile lithotripsi yapmıştır. Bu gelişmenin hemen ardından, yine 1953 yılında, “Yutkin” ELEKTRO HİDROLİK LİTHOTRİPTÖR”ü (EHL) keşfetmiştir. Yapılan araştırma ve geliştirme çalışmaları sonucunda ilk kez 1980 yılında “Caussy” tarafından ESWL hastalar üzerinde uygulanmaya başlanmıştır [24].

ESWL cihazları çalışma prensiplerine göre “Elektro Manyetik, Piezo-Elektrik, Elektro-Hidrolik” diye üçe ayrılırlar.

Taşa odaklanma “Ultrasonik” ve “X-ray” ile yapılmaktadır. Ayrıca ESWL cihazları odak büyüklüklerine göre küçük ve büyük odaklı olmak üzere ikiye ayrılırlar.

2.5.2 KIRILIM TEORİLERİ

Yüksek gerilim altında ve birbirine yeteri yakınlıkta iki elektrot arasında SPARK(KIVILCIM) oluşumu sağlanır.

1-Bu olay ; Basınç ve Gerginlik(Compressive and Tensile strenght) ile taşın kırılımına neden olur.


2-Son zamanlarda daha çok kabul gören bir teoriye göre ise spark sonucu oluşan “Yüksek Basıncılı Kabarcık” (YBK) taşta sağladığı kavitasyon etkisi ile kırışı sağlar.

2.5.3. YESD KAYNAKLARI

YESD başlıca 3 kaynaktan elde edilir.

2.5.3.1. ELEKTROMANYETİK KAYNAK

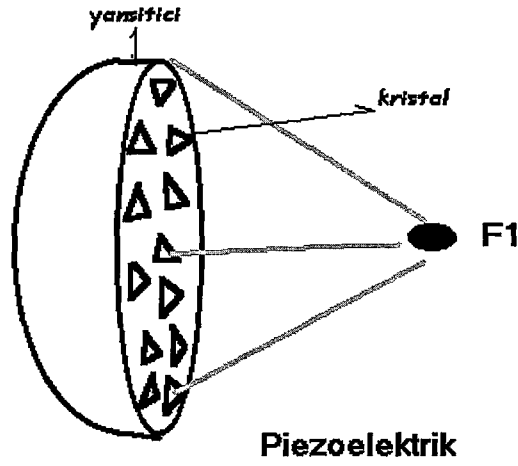
Çalışma prensibi kapı zilineki ile aynıdır. Bir elektromanyetik dalganın etki alanında titreşen metalik membrandan elde edilen yesd (sw:shock wave) akustik lens ile bir odağa (F1) yönlendirilirler böylece kırış sağlanır.



Şekil 2.5.1 Elektro Manyetik Kaynakla YESD elde edilmesi

2.5.3.2. PIEZOELEKTRİK KAYNAK

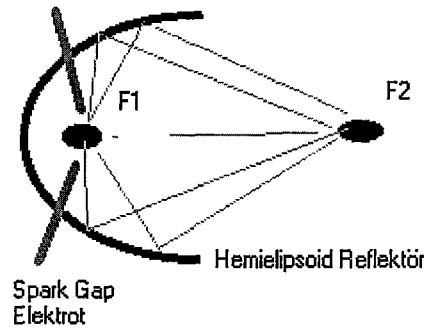
Kristaller bir elektrik alanında oldukça yüksek tınıda rezonansa geçireler oluşan yesd bir odağa(F1) yönlendirilerek kırış sağlanır.



Şekil 2.5.2 Piezo Elektrik kaynakla YESD elde edilmesi

2.5.3.3. ELEKTROHİDROLİK KAYNAK (EHK)

İçi su dolu elipsoid bir reflektörde, F1 odağında biri birine yakın iki elektroda yeteri voltaj uygulandığında SPARK(KIVILCIM) oluşur. Bu kıvılcım yesd(sw) oluşturur ve F2 odağına yönlendirilerek taş kırılır. Ayrıca spark ,cavitation bubble denen toplu iğne ucu büyüklüğünde enerji yüklü kabarcıkların oluşumuna neden olur. Bu da kırış sağlayan ikincil bir etkidir.



Elektrohidrolik

Şekil 2.5.3 Elektro Hidrolik Kaynakla YESD elde edilmesi

Son zamanlarda lazer ve mikro ekspulsif kaynaklı yesd da geliştirilmesine rağmen, henüz kullanımı yaygınlaşmamıştır.


2.5.4. TAŞ KIRILIM TEORİLERİ

- Basınç-Gerilim teorisi (Strong Compressive Tensile Wave Teori)

Taşa yönlendirilen yesd büyük bir basınç oluşturur(1000-1200 bar), taş da bu etkiye karşı tepki oluşturur ve bu sayede mikro kırıklar meydana gelerek taş sağlamlığını kaybeder.

- Yüksek Enerjili Kabarcık (YEK) (Cavitation Bubble)


Ultrasonik bir ses demeti sıvı ortam içerisinde geçerken YEK oluşumu bir fizik kuralıdır. Bu YEK saniyenin daha küçük bir zaman diliminde oluşur, şişer ve çökerek kaybolur. İşte bu esnada mikro jet akım meydana gelir, büyük bir negatif basınç oluşur ve asıl bu olayın taşta küçük oyuklar (cavitation), kırılmalar meydana getirdiği sanılmaktadır [25].



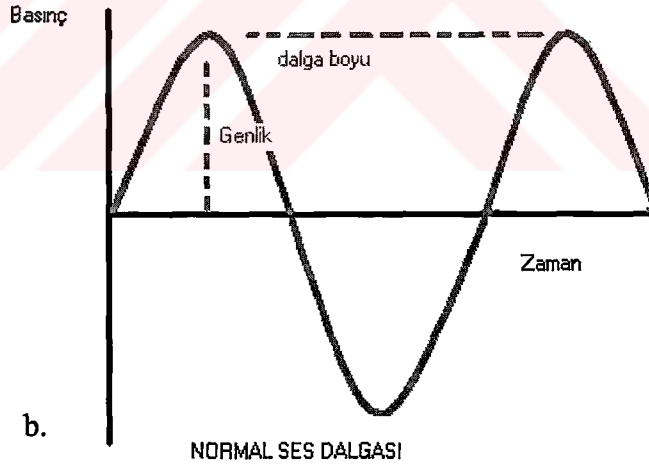
Şekil 2.5.4 Yek'in oluşumu

YEK, solda. Sağda ise YEK' in prinç levha üzerindeki tahrip edici etkisi

Nomalde ses dalgaları Şekil 2.5.5.b de görüldüğü gibi düşük seviyede titreşim enerjisidir ve basınç-zaman grafiklemesinde sinüsoidal yapıdadır. Oysa yesd (sw) Şekil 2.5.5.a da ki gibi oldukça yüksek enerjili, basınç-zaman grafiklemesinde dik , keskin çıkışlı, konkav bir eğri ile ifade edilir.



a.



b.

Şekil 2.5.5 Şok Dalgası ve Normal ses dalgası

2.5.4.1. KIRILGANLIK

- Taşların %90'ı eswl ile tedavi edilebilir.
- 1 cm kadar taşlar %60 bir seansta ,%40 diğer seanlarda kırılır.
- Taş kırılımlı için 16-20 kV, 1200-9000 sw gerekir.
- Bazen 150-200 sw de kırılma farkedilebilir.
- ESWL esnasında kırılmanın fark edilmesi

- Tam Kırılma % 80
- Muhtemel Kırılma % 15
- Anlaşılamaz % 3
- Genelde 2 gün sonra % 95 kırılma anlaşılır ve taştan temizlenme % 25 dir.

2.5.4.2. TAŞIN CİNSİ VE KIRILGANLIK

- 1) Çok Zor Kırılanlar: Cystin,Pür CaPO₄ (kalsiyum fosfat).
- 2) Zor Kırılanlar: Ca.OX.Monohidrat (kalsiyum oxalat monohidrat), Bazı ÜA(ürik asit), yaşlı struvit(MAP:magnesium amonyum fosfat)
- 3) Kolay Kırılanlar: Ca.OX.Dihidrat, Çoğu ÜA, Struvit(MAP)

2.5.4.3. TAŞIN YERLEŞİMİ VE KIRILGANLIK

- 1) Böbrek Taşı : % 95 kırılabilir
- 2) Üreter Üst ve Orta Kısım Taşı: % 90 kırılabilir
- 3) Üreter Alt Uç Taşı : % 60 kırılabilir

2.5.4.4. TAŞIN BÜYÜKLÜĞÜ VE KIRILGANLIK

Böbrek Taşları

- 2 cm altında % 96 kırılabilir
- 2 cm üzerinde %79 kırılabilir
- Staghorn % 30-70(PNL de % 60-90)

2.5.4.5. TAŞTAN TEMİZLENME (TT)

Kırılan taşlar üriner sistemi hemen terketmezler. Bu işlem için belli bir süre gerekir.

- 1.5 cm den küçük taşlar için 3 ayda TT % 92
- 2.5 cm den büyük taşlar için 3 ayda TT %50
- Genel olarak 1 ayda TT % 50 iken 3-6 ayda%75-80'e çıkar.

2.5.4.6. TAŞIN TEKRARLAMASI

Genelde % 50-100 tekrarlama olasılığından söz edilir. Bu oran toplumlar ve taş cinsleri arası farklılıklar gösterir.

Ca.OX için 1 yılda tekrar oluşum	% 10
5 '' '' ''	%35
10 '' '' ''	%50

Bu konularda ülkemizde yerel çalışmalar olmasına karşın kesin ve ulusal verilerimiz yoktur.

2.5.4.7. KOMPLİKASYONLAR

- Retroperitoneal kanama: % 5 sintigrafik olarak saptanmıştır.
- Hematüri: 12-24 saatte düzelir.
- Hipertansiyon: % 8 görülür. (Toplumda hipertansiyon zaten % 10 15 oranında görülmektedir.)
- Sepsis: % 3.5
- Nefron Kaybı: % 1-2
- Renal Trauma: MR incelemesinde %63-85 saptanabilir.Kısa sürede düzelir.
- Stone Street: Taş Caddesi:Taşların % 3'nde ,2-4 haftada görülür. Tedavisi gerekirse sıklıkla eswl ile yapılır.Bazen kateterizasyon, üreteroskopik girişim çok nadiren de ameliyat gerekebilir.
- GİS erozyonu, bulantı, kusma.

2.5.4.8. ESWL NİN DOKU ETKİSİ

- Lizozomal yırtılma ile yer yer hücrel oto digestion olur.
- Hücre membranlarının geçirgenliğini bozarak ödem yapabilir.
- Renal tübüler hücrelerde degenerasyon yapabilir.

2.5.4.9. KESİN KONTRENDİKASYON

- Gebelik
- Kanama Diatezi
- Distal Üreter Obstrüksiyonu
- Kreatinin yüksekliği(3mg/dl üzeri)

2.5.4.10. KISMI KONTRENDİKASYON

- Pace Maker
- Renal Arter Kalsifikasyonu
- UPO (üretero pelvik obstrüksiyon)
- Aritmi

2.5.5. TAŞ KIRMA YÖNTEMİNİN DİĞER KULLANIM ALANLARI

Eswt: Extra coporial shock wave terapi

1) Ortopedi

- Psedoarthrosis
- Geç iyileşen Kırıklar
- Tendinit
- Omuz Kireçlenmesi
- Topuk Kireçlenmesi
- Romatizmal Hastalıklar

2) Safra Kesesi Taşları

3) Tükürük Bezi Taşları

4) Estetik Cerrahide : Yağların giderilmesinde

5) Kadın Doğumda : Gecikmiş hamileliğin sonlandırılmasında

6) Veteriner Hekimliğinde : Ayak bileği kemiği kırıkları

Bacak kırıkları

**7) Çevre Koruması : A.B.D de deterjan kullanmaksızın çamaşırların
temizlik ve dezenfeksiyonunda (Bleu Wave Ultrasonografi).**



3. BULGULAR

3.1. ESWL AYGITININ BYSA İLE DENETİMİ

Uygulama olarak Extracorporal Shock Wave Lithotripsy (ESWL) aygıtının, atım frekansı, atım kuvveti ve yapılacak atım sayısı gibi parametrelerinin bulanık mantık sistemleri ile denetimi incelenmiştir. Geleneksel olarak, ESWL terapisi sırasında operatör x-ışını görüntülerini izleyerek bu parametreleri ayarlar. Parametrelerin belirlenmesi deneyim gerektirir, bu yüzden konusunda uzman ürologlar tarafından uygulanır. Bu çalışmada, terapistin kılavuzluk edecek şekilde x-ışını görüntülerini ve aygıt verilerini giriş olarak kullanarak, yapılması gereken aygıt ayarlarının çıkış olarak hesaplanması gerçekleştirilmiştir. Bu hesaplamada kullanılacak sistem bulanık mantık yöntemleridir. Ancak geleneksel bulanık mantık sistemlerinden farklı olarak, bulanık yapay sinir ağları kullanılmıştır. Bulanık yapay sinir ağlarında, üyelik fonksiyonu ve karar fonksiyonlarının parametre seçiminin programcı tarafından önceden yapılmasına gerek yoktur. Bunun yerine, ilişki parametreleri giriş çıkış verilerinden oluşan eğitim çiftlerine göre, geriye doğru algoritmasıyla sistem eğitilerek bulunur. Bu yüzden bulanık yapay sinir ağları daha önceki başarılı Lithotripsy uygulamalarının verilerinden yararlanarak geliştirilebilir.

3.2. YÖNTEM

Geleneksel uygulamada operatör kapalı çevrim sisteminin bir aşaması konumundadır. X-ışını görüntülerini ekrandan izleyerek taşın kırılma miktarını yorumlamaya çalışır. Bu çalışmada öncelikle ekrandaki taşın kırılma miktarına kantitatif bir yorum getirilmesine çalışılmıştır. Bu yorum görüntü işleme yöntemleri kullanılarak gerçekleştirilebilir.

3.3. GÖRÜNTÜ İŞLEME


Bir röntgen görüntüsünde böbrek taşı diğer dokulara oranla x-ışınlarını daha az geçirdiğinden, beyaz bir nokta olarak görünür. Böbrek taşı kırılmaya başladıkça bu beyazlık azalır, kumlaşma ilerledikçe x-ışınları daha fazla geçirileceğinden görüntüde o bölgedeki parlaklık azalır. Taşın bulunduğu bölge bir kez işaretlenip, x-ışını kaynağının enerjisinin sabit değerinde tutulması sağlanırsa ve aynı şekilde, görüntü elde eden sistemin kazanç parametreleri de sabit kalırsa, bölgenin parlaklığı, yani o bölgedeki görüntü işaretinin enerjisi, böbrek taşı kırıldıkça azalır. Bu enerji değeri, resim noktalarının genliklerinin karekökleri ortalaması gibi belirli bir metriğe bağlı normalizasyon işlemi kullanılarak sayısal olarak ifade edilebilir. Bu da böbrek taşının kırılma miktarıyla ilgili bir veri olarak değerlendirilebilir. Ancak bulanık yapay sınır ağlarının eğitimi başka bir görüntü verisi üzerinden yapıldıysa, öncelikle görüntülerde seçili görüntü hücresi sayısına göre enerjinin ölçeklenmesi gerekir. Ayrıca yeni görüntü üzerinde önceki görüntülerin verilerine dayanarak histogram uydurması yapılmalıdır.

Sözelimi Şekil 3.1.2 deki işaretlenen bölgedeki resim hücrelerinin parlaklık değerlerinin karekökleri ortalaması ile enerjisi hesaplandığında şu değerler elde edilmiştir.

Böbrek taşı için : 4.7758×10^4

Kırılmış böbrek taşı için : 4.3081×10^4

İki değer arasındaki fark : 4.6763×10^3



Şekil 3.1.2 Böbrek taşı resimleri. Resimde sol tarafta böbrek taşı ve sağ tarafta kırılmış böbrek taşı görülmektedir.


Görüntü işleme aşamasında kullanılabilir ve başarılı olan bir diğer yöntem ise kenar bulma yöntemidir. Kenar bulma işleminde kullanılan sınır değeri çok keskin tutulmadığı durumlarda gri-tonlamalı bir resimde karşıtlık miktarı yüksek olan bölgeler yakalanabilir. Böbrek taşı kırılmaya başladığında, x-ışını görüntüsü üzerinde yer yer karşıtlık değişimleri görülecektir. Bu değişimler kenar bulma yöntemiyle yakalanıp kenar noktası olarak işaretlenirse ve daha sonra seçilen bölgede kenar sayısı olarak işaretlenmiş resim hücreleri sayılırsa bu sayının taş kırıldıkça arttığı görülür. Yukarıda anlatılan yöntemde olduğu gibi bu yöntemde de eğitimde kullanılan daha önceki verilerle uyumluluğun sağlanması x-ışını görüntüsü üzerinde işaretlenen bölgenin alanının resim noktası sayısına oranının değerlendirilmesi gerekir. Ve yine resimler üzerinde histogram eşleştirilmesi yapılmalıdır. X-ışını kaynağının enerjisinin sabit tutulması bu yöntem için daha hassas değerlendirilmesi gereken bir konudur. Eğer bunun yeterince sağlanamadığından kuşku duyuluyorsa ardışık birkaç x-ışını görüntüsünün verileri değerlendirilerek alçak geçiren etkili bir ortalama değer süzgecinden geçirilmesi gerekir.

Şekil 3.1.3’de görülen örnekte taşın bulunduğu işaretli bölgede böbrek taşı ve kırılmış böbrek taşı için uygun bir eşik değeri belirlendikten sonra sayılan kenar noktaları için aşağıdaki değerler bulunmuştur.

Böbrek taşı için : 3309 nokta

Kırılmış böbrek taşı için : 3980 nokta

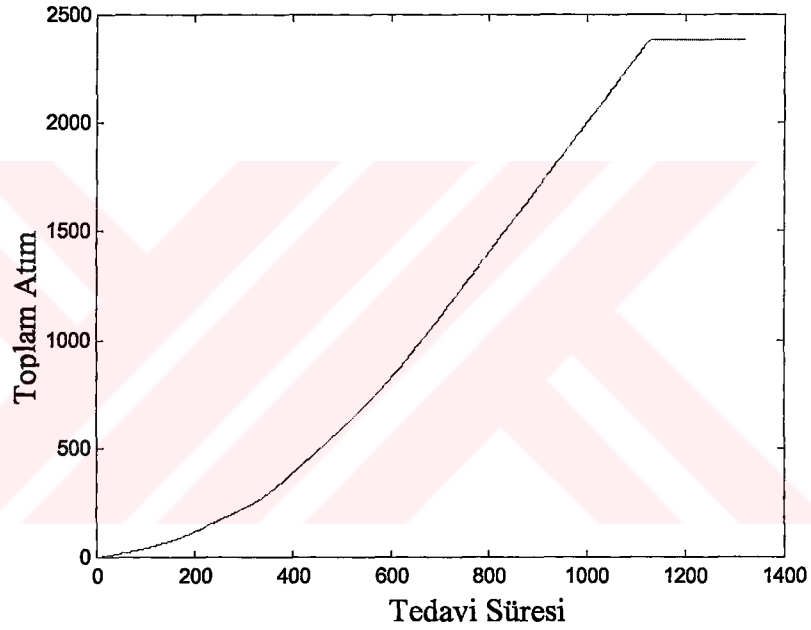
İki değer arasındaki fark : 671 nokta




Şekil 3.1.3 Solda böbrek taşı ve sağda kırılmaya başlamış böbrek taşı görülmektedir.

3.4. BULANIK YAPAY SİNİR AĞI UYGULAMASI


Bulanık Yapay Sinir Ağı (BYSA) tasarlanırken ESWL de yapılan atım sayısı yani bir anlamda terapi süresi ve x-ışını görüntüsünde işaretlenen bölgedeki kenar noktası sayısı giriş olarak kullanılmıştır, bulanık yapay sinir ağının bu değerlere karşılık gelen atım frekansını hesaplaması istenmiştir. Eğitimde kullanılacak veriler başarılı bir ESWL operasyonunda elde edilmiş verilerdir. Bulanık mantık sisteminin kontrolü ise bir diğer seansta aynı hastaya aynı makine ayarlarıyla yapılan operasyonun verileriyle gerçekleştirilmiştir.



Şekil 3.1.4 Seans boyunca yapılan toplam atım sayısının zamana göre değişimi




Şekil 3.1.5 X-ışını görüntülerindeki kenar noktaları sayısının zamana bağlı değişimi




Şekil 3.1.6 Atım frekansının zamana göre değişimi

Simülasyonlarda Sugeno tipi bulanık yapay sinir ağı kullanılmıştır.




Şekil 3.1.7 Simülasyon Modeli

Bulanık yapay sinir ağı giriş çıkış ilişkilerinin örneklerinden oluşan eğitim çiftleriyle eğitildiğinde yapay sinir ağının üyelik fonksiyonları ve kural fonksiyonu parametreleri belirlenmiş olur. Eğitimde geri yayılım algoritması kullanılmıştır.




Şekil 3.1.8 Toplam kenar noktası sayısı girişleri için 10 üyelik fonksiyonunun bölgesi




Şekil 3.1.9 Toplam atım sayısı girişleri için 10 üyelik fonksiyonu girişlerinin bölgesi

Eđitim ile üyelik fonksiyonlarının parametreleri belirlenmiştir.




Şekil 3.1.10 Üyelik fonksiyonlarına göre örnek kuralların aldıkları değerler

Üyelik fonksiyonlarının parametreleriyle belirlenmiş olan giriş çıkış ilişkileri, iki boyutlu giriş ve tek bir çıkış için, bir değerler yüzeyiyle gösterilebilir.



Şekil 3.1.11 Giriş-Çıkış ilişkilerine göre, bulanık mantık sisteminin değer yüzeyi



Şekil 3.1.12 ESWL hata miktarı. ESWL aygıtının atım frekansı için bulanık mantık sisteminin öngördüğü değerler ile uygulayıcının yürüttüğü değerler arasındaki hata miktarı

4. TARTIŞMA VE SONUÇLAR

Yapılan bu çalışmada, böbrek taşı kırma işleminde, x-ışını görüntülerinin, görüntü işleme yöntemleriyle değerlendirilmesi sonucunda taşın kırılma miktarı ile ilgili belirli bir metrik öne sürmemize yardımcı olacak verilerin elde edilebileceği gösterilmiştir. Bu yaklaşım doğrultusunda, görüntünün parlaklık değerlerinden yapılacak bir enerji hesaplamasının ya da yumuşak eşik değerine sahip kenar bulma işleminden sonra işaretlenen kenar noktalarının sayılmasının uygun olduğu anlaşılmıştır.

Bulanık Yapay Sinir Ağları'nın (BYSA) performansının geleneksel çok katmanlı perseptronlardan yüksek olduğu literatürdeki çeşitli kaynaklarda ifade edilir. Bu çalışmada da BYSA'lar verimli sonuçlar üretmiştir. Kısa eğitim çevrimlerinde giriş çıkış ilişkilerini oluşturacak modellere yakınsanabilmiştir.

Görüntü işleme algoritmaları ve BYSA'lar uygun biçimlerde birlikte kullanıldığında bir çok alanda olabileceği gibi tıp uygulamalarında da başarılı sonuçlar üretebilirler. Yüksek enerjili akustik şok dalgalarıyla böbrek taşı kırma işleminde, operasyon verilerinin değerlendirilmesinde BYSA'ların kullanılması, zamanla yaygınlaşabilecek başarılı bir uygulamadır.

5. KAYNAKLAR

- [1] DUDGEON, D.E. and R.M. MERSEREAU, *Multidimensional Digital Signal Processing*. (1984), Englewood Cliffs, New Jersey: Prentice-Hall.
- [2] FREEMAN, H, *Boundary encoding and processing*, in *Picture Processing and Psychopictorics*, B.S. Lipkin and A. Rosenfeld, Editors. (1970), Academic Press: New York. p. 241-266.
- [3] YOUNG, IAN THEODORE, GERBRANDS, JAN JACOB ,VAN VLIET, LUCAS JOZEF , (1995), *Fundamentals Of Image Processing* ISBN 90-75691-01- 7 NUGI 841 Den Haag
- [4] J. MOODY AND C. J. DARKEN, Fast learning in networks of locally-tuned processing units,(1989), *Neural Computing*, 1, pp. 281-294.
- [5] T. KOHONEN, "Self-organizing map,(1990), *Proc. IEEE*, vol. 78, no. 9, pp. 1464-1480.
- [6] R. P. LIPPMANN. An introduction to computing with neural networks.(1987), *IEEE Acoustics,Speech , and Signal Processing Magazine*, 4(2): 4-22.
- [7] T. KOHONEN. *Self-Organization and associate memory*. (1989), Springer-Verlag, 3rd edition, London.
- [8] T. KOHONEN. Improved versions of learning vector quantization, (1990), *International Joint Conference on Neural Networks*, Pages Vol. 1: 545-550, San Diego.
- [9] J.J. HOPFIELD. Neural Networks and physical systems with emergent collective computational abilities, (1982), In *Proceeding of the National Academy of Science, USA , pages 2554-2558*.

- [10] ELMAN, J.L. (1990), Finding structure in time, *Cognitive Science*, 14, 179-211.
- [11] JORDAN, M. I. (1986), Attractor dynamics and parallelism in a connectionist sequential machine, In Proceedings of the Eighth Annual conference of the Cognitive Science Society, pages 531-546. Lawrence Erlbaum.
- [12] RUMELHART, D.E. AND MCCLELLAND, J. L., eds. (1986), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Volume 1, 318-362, Cambridge, MA: The MIT Press.
- [13] M. R. W. DAWSON AND D. P. SCHOPFLOCHER. Modifying the generalized delta rule to train networks of non-monotonic processors for pattern classification (1992) , *Connection Science*, 4:19-31.
- [14] KOHONEN, T. (1988), Learning Vector Quantization, *Neural Networks*, 1 (suppl 1), 303.
- [15] FAUSETT, L. (1994), *Fundamentals of Neural Networks*, Englewood Cliffs, NJ: Prentice Hall.
- [16] CARPENTER, G.A., GROSSBERG, S. (1987a), A massively parallel architecture for a self - organizing neural pattern recognition machine, *Computer Vision, Graphics, and Image Processing*, 37, 54-115.
- [17] CARPENTER, G.A., GROSSBERG, S. (1987), ART 2: Self-organization of stable category recognition codes for analog input patterns, *Applied Optics*, 26, 4919-4930.

- [18] CARPENTER, G.A., GROSSBERG, S. (1990), ART 3: Hierarchical search using chemical transmitters in self-organizing pattern recognition architectures. *Neural Networks*, 3, 129-152.
- [19] L. A. ZADEH, Fuzzy sets, *Information and Control*, (1965), vol. 8, pp. 338-353.
- [20] DRIANKOV, D., HELLENDORN, H., REINFRANK, M., (1993), *An introduction to Fuzzy Control*, Springer-Verlag, NY.
- [21] H. BANDEMER AND S. GOTTWALD, *Fuzzy Sets, Fuzzy Logic, Fuzzy Methods with Applications*, (1995), (John Wiley and Sons, Chichester, New York, Brisbane, Toronto, Singapore,
- [22] T. TAKAGI AND M. SUGENO, Fuzzy identification of systems and its applications to modeling and control, (1985) *IEEE Trans. Syst., Man, Cybern.*, vol SMC-15, no. 1, pp. 116-132.
- [23] S. R. JANG, ANFIS: adaptive-network-based fuzzy inference system, (1993), *IEEE Trans. Syst., Man, Cybern.*, vol. 23, no. 3, pp. 665-685.
- [24] CHAUSSY CG, FUCHS GJ, Current state and future developments of noninvasive treatment of human urinary stones with extracorporeal shock wave lithotripsy. *J Urol* (1989) Mar, 141(3 Pt 2): 782-9
- [25] DELIUS M, This month in Investigative Urology: effect of extracorporeal shock waves on the kidney. *J Urol* (1988) Aug, 140(2): 390
- [26] GEORGE J. KLIR, BO YUAN, *Fuzzy Sets and Fuzzy Logic; Theory and Applications* (1995) May, Prentice-Hall, New York.

6. ÖZGEÇMİŞ

1975 yılında Bingöl'de doğdu. İlk Orta ve Lise öğrenimini yine Bingölde tamamladı. Temmuz 1999 tarihinde İstanbul Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği bölümünden mezun oldu. Ağustos 1999 tarihinde İstanbul Üniversitesi Fen Bilimleri Enstitüsü'nde Biyomedikal Mühendisliği bölümünde Yüksek Lisans yapmaya hak kazandı. Aralık 2000 tarihinde İstanbul Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü Devreler ve Sistemler Anabilimdalı'nda Araştırma Görevlisi olarak göreve başladı. Aralık 2000 tarihinden bu yana aynı görevde çalışmaktadır.