

**T.C.
HALIÇ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİK ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ PROGRAMI**

**İŞLENMİŞ HAYVANSAL DERİLERİN YÜZEY
YAPILARININ VE RENK TONLARININ
SINIFLANDIRMA YÖNTEMİ İLE TANIMLANMASI**

YÜKSEK LİSANS TEZİ

**Hazırlayan
İlyas AYDOĞAN**

**Danışmanı
Yrd.Doç.Dr. Murat BEKEN**

İstanbul – 2011

**T.C.
HALIÇ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİK ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ PROGRAMI**

**İŞLENMİŞ HAYVANSAL DERİLERİN YÜZEY
YAPILARININ VE RENK TONLARININ
SINIFLANDIRMA YÖNTEMİ İLE TANIMLANMASI**

YÜKSEK LİSANS TEZİ

**Hazırlayan
İlyas AYDOĞAN**

**Danışmanı
Yrd.Doç.Dr. Murat BEKEN**

İstanbul – 2011

T.C.
HALIÇ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programı Tezli Yüksek Lisans öğrencisi İlyas AYDOĞAN tarafından hazırlanan “İşlenmiş Hayvansal Derilerin Yüzey Yapılarının ve Renk Tanlarının Sınıflandırma Yöntemi ile Tanımlanması” adlı bu çalışma jürimizce Yüksek Lisans Tezi olarak kabul edilmiştir.

Sınav Tarihi : 30.09.2011

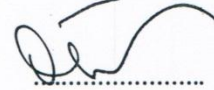
(Jüri Üyesinin Ünvanı , Adı , Soyadı ve Kurumu) :

İmzası :

Jüri Üyesi: Yrd.Doç.Dr.Murat BEKEN
Dan.-HAL.Üniv. Matematik ABD Öğr.Üyesi


.....

Jüri Üyesi : Yrd.Doç.Dr.Oğuz KARAN
HAL.Üniv. Bilgisayar Müh.ABD Öğr.Üyesi


.....

Jüri Üyesi : Yrd.Doç.Dr.Ulviye HACIYEVA
HAL.Üniv. Bilgisayar Müh.ABD Öğr.Üyesi


.....

Jüri Üyesi : Prof.Dr.Mübariz EMİNLİ
HAL.Üniv. Müh.ABD Öğr.Üyesi (Yedek)

.....

Jüri Üyesi : Yrd.Doç.Dr.Tayfun YEGÜL
HAL.Üniv. Matematik ABD Öğr.Üyesi (Yedek)

.....

ÖNSÖZ

Tez konum olan işlenmiş hayvansal derilerin yüzey yapılarının ve renk tonlarının sınıflandırma yöntemi ile tanımlanması'nı giysilik deri üretimi ile ilgilenen gerek ithalat gerekse ihracat yapan üretici firmalarımızın daha kaliteli ürünler çıkararak Dünya piyasasındaki yerlerini ileri seviyelere taşımasına katkıda bulunabilmek için hazırlamış bulunmaktayım.

Haliç Üniversitesindeki eğitim hayatım boyunca tecrübelerini ve değerli bilgilerini bizimle paylaşan çok değerli hocalarıma,

Bitirme olarak seçtiğim bu konuda ilgisini ve yardımını benden hiçbir zaman esirgemeyen tez danışmanım hocam Murat BEKEN'e,

Bugünlere gelmemde en önemli paya sahip, benden hiçbir zaman sevgilerini ve desteklerini esirgemeyen başta babam H.Şükrü AYDOĞAN, annem H.İmmihan AYDOĞAN ve bütün aileme,

Bu tez çalışmam boyunca benden desteğini eksiltmeyen ve motive eden sevgili eşim Züleyha AYDOĞAN'a,

Sonsuz teşekkürlerimi sunarım.

İstanbul, 2011

İlyas AYDOĞAN

İÇİNDEKİLER

	<u>Sayfa No.</u>
KISALTMALAR LİSTESİ	IV
TABLolar LİSTESİ	V
ŞEKİLLER LİSTESİ.....	VI
ÖZET	VIII
ABSTRACT	IX
1. GİRİŞ.....	1
2. DERİNİN YAPISI	3
2.1. Derinin Yapısı.....	3
2.2. Derinin Kimyasal Yapısı	5
2.3. Deri Çeşitleri.....	6
2.4. Deri Kalitesini Etkileyen Faktörler	7
2.5. Deri Durumu	7
2.6. Deri İşleme	8
2.7. Deri Üretim Aşamaları	9
2.8. İşlenmiş Deri Örnekleri	10
3. YAPAY SİNİR AĞLARI (YSA)	11
3.1. Yapay Sinir Ağlarının (YSA) Genel Tanımı	11
3.2. YSA' ların Temel Özellikleri	11
3.3. YSA' nın Avantaj ve Dezavantajları	12
3.4. YSA' nın Kullanıldığı Alanlar	12
3.5. YSA' nın Gelişimi	13
3.6. Biyolojik Nöron ve Yapay Sinir Modeli.....	15
3.7. YSA' nın Yapısı ve İşlem Elemanı.....	17
3.8. Giriş İşareti Sınıfları	17
3.9. Bağlantı Geometrilere	19
3.10. Ağ Tipleri	20
3.11. Eşik Fonksiyonları.....	20
4. YSA'DA EĞİTME ve ÖĞRENME.....	23
4.1. Giriş	23

4.2. Öğreticili Eğitim (supervised training)	23
4.3. Skor ile eğitim (graded training)	23
4.4. Öğreticisiz Eğitim (unsupervised training)	24
4.5. Ağırlık Uzayı	24
4.6. Bellek ve Genelleme.....	25
4.7. Hata Toleransı.....	25
4.8. Non-Linear ve Paralellik.....	25
4.9. Öğrenme Stratejileri.....	26
4.10. Perceptron.....	26
4.11. Çok katmanlı perceptron(Multi-Layer Perceptron)	29
4.12. Hatanın geriye yayılması algoritması ve genelleştirilmiş delta kuralı	30
4.13. Öğrenme ve Momentum Katsayıları.....	35
5. YAPAY SİNİR AĞI İLE DERİ YÜZEYİ VE RENK TONU SINIFLANDIRMA UYGULANMASI	37
5.1. İşlenmiş Hayvansal Derilerin Elde Edilmesi	38
5.2. Öznitelik Çıkarma.....	39
5.2.1. Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)	39
5.3. YSA'nın Eğitilmesi	43
5.4. Test Edilmesi	49
6. SONUÇ.....	58
7. KAYNAKLAR	60
8. ÖZGEÇMİŞ.....	63

KISALTMALAR LİSTESİ

- A.g.e.** : Adı geçen eser
A.g.m. : Adı geçen makale
S. : Bakınız
MSE : Mean Square Error (Ortalama Karesel Hata)
MLP : Multi Layer Perceptron (Çok Katmanlı İdrak)
ART : Adaptive Resonance Theory (Uyarlanabilir Rezonans Teorisi)
PDP : Parallel Distributed Processing (Paralel Dağılımlı İşleme)
Y.S.A : Yapay Sinir Ağları
Asorti : Deri renk ve yüzey uyumluluğu

TABLO LİSTESİ

Sayfa No.

Tablo 5. 1: En iyi Momentum ve Öğrenme Oranının Belirlenmesi	47
Tablo 5. 2: Eğitim Değerleri	47
Tablo 5. 3: 3000'er iterasyonlu grafik	57
Tablo 5. 4: 5000'er iterasyonlu grafik	57

ŞEKİL LİSTESİ

Sayfa No.

Şekil 2. 1: Kılın Histolojik Yapısı	4
Şekil 2. 2: Derinin Kimyasal Yapısı	5
Şekil 2. 3: Küçük Baş	6
Şekil 2. 4: Büyük Baş Hayvanlar.....	6
Şekil 2. 5: Av Hayvanları	6
Şekil 2. 6: Derinin Kısımları.....	7
Şekil 2. 7: Ham Deriyi Tabaklamaya Hazırlama	8
Şekil 2. 8: Deri Üretim Aşamaları	9
Şekil 2. 9: İşlenmiş Deri Örnekleri	10
Şekil 3. 1: Biyolojik sinir hücresinin yapısı.....	15
Şekil 3. 2: Nöron modeli	16
Şekil 3. 3: Tek Katmanlı YSA.....	18
Şekil 3. 4: Çok katmanlı YSA	18
Şekil 3. 5: YSA Sınıflandırıcıları	19
Şekil 3. 6 Sık Kullanılan Eşik Fonksiyonları.....	22
Şekil 4. 1: Üç boyutlu uzayda ağırlık vektörünün değişimi.....	24
Şekil 4. 2: Tek katmanlı perceptron.....	27
Şekil 4. 3: Lineer ayrılabilirliğin gösterimi	27
Şekil 4. 4: Tek katmanlı perceptron ile iki ve üç katmanı bulunan çok katmanlı perceptronlar.	28
Şekil 4. 5: Hatanın geriye yayılması algoritmasının blok diyagramı.....	30
Şekil 4. 6: Gizli katmanı olmayan ağırlık hata fonksiyonu	31
Şekil 4. 7: Gizli katmana ait ağırlık hata fonksiyonu	32
Şekil 4. 8: Hatanın Geriye Yansımaları Algoritmasının akış diyagramı	36
Şekil 5. 1: İşlenmiş Hayvansal Derinin Sınıflandırılması.....	37
Şekil 5. 2: İşlenmiş Hayvansal Derinin Normal Boyutu.....	38
Şekil 5. 3: Küçültülmüş İşlenmiş Hayvansal Deri	39
Şekil 5. 4: Gri ye Dönüştürülmüş İşlenmiş Hayvansal Deri.....	39
Şekil 5. 5: Contour Kullanılarak Elde Edilen Görüntü	42
Şekil 5. 6: MLP Mimarisi Siyah Renk.....	43
Şekil 5. 7: MLP Mimarisi Siyah Yüzey.....	44

Şekil 5. 8: MLP Mimarisi Kahve Renk	44
Şekil 5. 9: MLP Mimarisi Kahve Yüzey	44
Şekil 5. 10: Kullanılan Program Renk Belirleme	45
Şekil 5. 11: Kullanılan Program Yüzey Belirleme	46
Şekil 5. 12: Hatanın İterasyona Göre Değişim Grafiği.....	48
Şekil 5. 13: İterasyonun Hataya Göre Değişim Grafiği.....	48
Şekil 5. 14: Siyah Renk Verilerinin Eğitilmiş Hali	49
Şekil 5. 15: Eğitilmiş Siyah Renk Veri Setinin Test Sonucu.....	50
Şekil 5. 16: Eğitilmemiş Siyah Renk Veri Setinin Test Sonucu.....	50
Şekil 5. 17: Eğitilmemiş Siyah Renk Veri Setinin Test Sonucu – 2.....	51
Şekil 5. 18: Siyah Yüzey Veri Setinin Eğitilmiş Hali.....	51
Şekil 5. 19: Eğitilmemiş Siyah Yüzey Veri Setinin Test Sonucu.....	52
Şekil 5. 20: Eğitilmemiş Siyah Yüzey Veri Setinin Test Sonucu – 2.....	52
Şekil 5. 21: Kahve Renk Verilerinin Eğitilmiş Hali	53
Şekil 5. 22: Eğitilmiş Kahve Renk Veri Setinin Test Sonucu	53
Şekil 5. 23: Eğitilmemiş Kahve Renk Veri Setinin Test Sonucu	54
Şekil 5. 24: Eğitilmemiş Kahve Renk Veri Setinin Test Sonucu – 2.....	54
Şekil 5. 25: Kahve Yüzey Veri Setinin Eğitilmiş Hali	55
Şekil 5. 26: Eğitilmiş Kahve Renk Veri Setinin Test Sonucu	55
Şekil 5. 27: Eğitilmemiş Kahve Yüzey Veri Setinin Test Sonucu.....	56
Şekil 5. 28: Eğitilmemiş Kahve Yüzey Veri Setinin Test Sonucu – 2.....	56

GENEL BİLGİLER

Adı ve Soyadı : İlyas AYDOĞAN
Anabilim Dalı : Bilgisayar Mühendisliği
Programı : Bilgisayar Mühendisliği
Tez Danışmanı : Yrd.Doç.Dr. Murat BEKEN
Tez Türü ve Tarihi : Yüksek Lisans – Eylül 2009

İŞLENMİŞ HAYVANSAL DERİLERİN YÜZEY YAPILARINA VE RENK TONLARINA GÖRE SINIFLANDIRMA YÖNTEMİ İLE TANIMLANMASI

ÖZET

Bu tez çalışmasında giysilik deri üretim sektörünün kesim aşamasının öncesinde yapılan işlenmiş hayvansal derilerin sınıflandırılması aşamasında insan gözünün ve hata payının minimize edilerek iş gücünün arttırılması ve maliyetlerin düşürülmesi hedeflenmektedir. Günümüzde deri sektöründe hala insan faktörünün çok büyük etkisi olmasına karşın bu yapmış olduğum tez sayesinde insan faktörünün yanı sıra bilgisayarlı sınıflandırma ve tanımayla hata payı ile maliyetin azaltılarak verimliliğin, kalitenin ve iş gücünün arttırılmasını amaçlanmaktadır.

Anahtar Kelimeler: Deri, Yüzey Yapısı, Kalite, Yapay Sinir Ağları, Sınıflandırma.

GENERAL KNOWLEDGE

Name and Surname : İlyas AYDOĞAN
Field : Computer Engineering
Program : Computer Engineering
Supervisor : Asst.Prof.Dr. Murat BEKEN
Degree Awarded and Date : Master – September 2009

Classification Of Clothing Leather Manufacturing In Colors And Surface

ABSTRACT

Before the cutting stage of clothing leather manufacturing industry, processed animal skins classification stage is being done with human eye. This study's purposes are increase the workforce and reduce the costs by minimizing errors.

Today in the leather industry, human factor is still a big effect and with this study, classification will be done by computers. In this way human factors in errors will be solved, the cost of efficiency will reduce and workforce will increase.

Keywords: Leather, Surface, Quality, Artificial Neural Network, Classification.

1. GİRİŞ

Bu tez çalışmasının amacı giysilik deri üretici firmalarının işlenmiş hayvansal derilerinin kesim aşamasından önce ki asorti aşamasını bilgisayarlı ortamdaki kontrolü sağlanarak hata payının minimize edilmesidir. Giysilik deri üretimindeki firmaların şuan ki sistemde bu işi insan gözü ve bilgisiyle devam ettirdikleri göz önüne alınacak olursa hataların kaçınılmaz olduğu aşikârdır.

Hazırlamış olduğum bu tez sayesinde asorti aşamasının daha düzgün ve güvenilir bir hale getirilerek kalite artırımı, zaman kazancı, insan faktörünün azaltılarak verimliliğin artırılması ve maliyetlerin düşürülmesi, iş gücünün artırılması hedeflenmektedir.

Bu konuya yakın bazı çalışmalar yapılmıştır. Ancak işlenmiş hayvansal derilerin yüzey yapısı ve renk tonlarına göre sınıflandırma yapılmamıştır. Bu konularda genellikle derilerin üzerindeki hataların tespiti yapılmaya çalışılmıştır. Aşağıda kısaca yaptıkları yöntem ve elde ettikleri verilere değinilmiştir.

Jang-Woo Kwon ve diğerleri¹, deri kalitesinin derinin yoğunluğuna ve deri arızalarının belirlenmesiyle karar verileceğini belirtmişlerdir. Doku analizleri ve modelleme süreçlerini iki yöntemle ayrılabilceğini bunların istatistiksel ve sinyal işleme yöntemleri olduğunu söylemişlerdir. Yapısal yöntemin hazır tekstil ürünlerinde sürekli tekrarlayan desenlerde uygulanabileceği ancak doğal tekstil ürünleri gibi rastgele yapılar için bu uygulamanın zor olacağını belirtmişlerdir. Bundan ötürü hazırlamış oldukları çalışmada Fourier dağılımını kullanmışlardır. Sonuç olarak Fourier dönüşümü dönüştürme işleminde zamanlama kısıtlaması nedeniyle bütün deri görüntü boyutu ve bütün deri yoğunluğunun doğru hesaplanmasının kolay olmadığı ifade etmişlerdir.

¹ J.W.Kwon, Y.Y. Choo, H.H. Choi, J.M. Cho, G.S.Kil, *Development of Leather Quality Discrimination System by texture Analysis*. Dept. of Computer Eng., T.I.T., Pusan, South Korea

Choonjong Kwak ve diğeri², hazırlamış oldukları çalışmada yapay sinir ağları ile arıza, sorun ve kusur tanıma gibi sınıflandırma işlemlerinde yapay sinir ağlarının gayet başarılı sonuçlar sağladığını belirtmektedirler. Deri gibi doku analizi gerektiren çalışmalar için yapay sinir ağlarında iki katmanlı ağların, üç katmanlı ağlara göre daha iyi sonuçlar verdiğini tespit etmişlerdir. Görüntüler alınırken en önemli faktörlerin aydınlatma ve kamera ile deri arasındaki mesafenin olduğunu, aydınlatmadaki önemli farklılıkların yanlış sonuçlara yol açabileceğini ve aydınlatmanında deri türüne göre ayrıca belirlenip uygun ortama göre çalışılması sağlandığı takdirde sonucun daha garanti altına alacağını belirtmektedirler.

Deri, doğanın en lüks ve aynı zamanda en pratik materyallerinden biridir. Her deri, hayvanın genetik yapısına, yaşadığı çevreye ve beslenme şekline göre dokusal farklılıklar gösterir. Bir derinin cildindeki izler ve kırışıklıkların oluşturduğu benzersiz doku derinin doğal güzelliğini ve eşsizliğini temsil eder. Tabaklanan deriler, boyanıp finisaj işlemleri yapıldıktan sonra deneyimli ustalar tarafından rengi ve dokusuna göre seçilerek gruplanır. Ürünün modeline göre farklı adetlerde hayvan derisi kullanılır, örneğin bir bayan blazer ceket minimum beş ayrı hayvanın biraraya gelmesiyle oluşur. Her deri, kol, boyun, gövde ve giysinin diğer parçalarının kalıplarından el ile kesilir. Daha sonra kesilen parçalar dikilerek seçmiş olduğunuz ürün ortaya çıkar.

² Kwak, C., Ventura, J. A. and Tofang-Sazi, K. (2000) A neural network approach for defect identification and classification on leather fabric. Department of Industrial and Manufacturing Engineering. The Pennsylvania State University, University Park, PA.

2. DERİNİN YAPISI

Deride doku ve tabakalar bulunur. Bu dokular epitel doku, bağ ve destek dokusu, kas dokusu ve sinir dokusudur.

Epitel Doku: Bedenin hava ile temas eden üst yüzeyini ve etle yapışık olan iç yüzeyini kaplar.

Bağ dokusuna benzer alt tabakadan geçen kan damarlarınca beslenen hücrelerden oluşmuştur. Üst deri çok katlı epitel dokulardan meydana gelmiştir.

Gelişimini tamamlamış hayvanlarda en üst epitel doku hücreleri boynuzlaşarak sağlam bir koruyucu tabaka haline gelir.

Bağ ve Destek Dokusu: Deride en kalın tabakayı oluşturur. Birçok protein çeşitlerinden meydana gelmiştir. Bunlardan kolegen, keratin ve elastin fazla miktarda bulunan proteinlerdir.

Sinir Dokusu: Sinirler, sinir hücrelerinden meydana gelir. Deri tabakasının en üstünde bulunurlar.

Sinirler miktar olarak çok az ve ince bir yapıda dağılmışlardır. Deri üretimi açısından önemsizdir.

Kas Dokusu: Deride bulunan kaslar; kıl kası, yağ ve ter bezleri çevresindeki kaslardır. Kıl kası kılın hareketini sağlar ve yağ bezlerinden yağın boşalmasına yardımcı olur. Kıllar kıl kökü ve sırcaya elastik lifleri ile tutunmuşlardır. Kıl kasları yapılanmış proteinden oluşmuşlardır. Kireçlik ve sama işleminden etkilenmez³.


2.1. Derinin Yapısı

Omurgalıların derileri üç tabakadan oluşmuştur. Ancak bunlar yapıları, kimyasal bileşimleri ve fizyolojik görevleri yönünden farklılık gösterirler.

Bu üç tabaka;

Üst deri (epidermis)
Öz deri (corium)
Alt deri (subcutis)

³ (MEGEP, 2007)



Şekil 2. 1: Kılın Histolojik Yapısı

2.1.1. ÜST DERİ

Üst deri tabakası, canlı hayvanın derisini idame ettiren, en önemli yaşamsal işlevleri kapsayan tabakadır. Vücudun tümünü dıştan kuşatarak onu çarpma ve darbelere karşı korur. Ayrıca; hayvan vücudunun ısı ve nem oranını ayarlar ve bakterilerin etkilerine karşı vücudu muhafaza eder. Üst deri, hücrelerden oluşmuş bir dokudur ve birçok tabakadan meydana gelmiştir.

2.1.2. ÖZ DERİ

Öz deri tabakası üst derinin (epidermis) hemen altında bulunur. Derinin koruyucu tabakası olarak görev yapar ve vücudu mekanik etkilerden korur. Derinin en kalın tabakasıdır ve toplam kalınlığının % 80'inden daha fazladır. Yapısı üst deriye göre farklıdır. Üst deride epitel doku hücrelerinin yerini öz deride bağ doku hücreleri alır. Bağ doku hücreleri birbirleriyle iç içe geçen ve ince bağlarla bağlanmış protein liflerinden oluşmuştur.

Deri üretiminde en önemli tabakadır.

Öz deri tabakasında bulunan protein türü KOLAGEN dir. Öz derideki bütün lif ve fibriller kolegen denilen bu proteinden meydana gelmiştir⁴.


⁴ PAPAĞÇI Selver, Kıvırcık ve Dalgıç Irkı Kuzu Derilerindeki Kolagen Miktarının Tayini ve Bunun Mamul Deri Üzerine Etkisi, Dericilik Araştırma Enstitüsü, Pendik-İstanbul.

2.1.3. ALT DERİ

Alt deri bağ dokusu, derinin en altında bulunan kas dokusuyla deriyi ete bağlayan bölümünü oluşturur. Alt derinin gevşek dokusu hayvan vücudundaki kayma ve katlanma özelliğini ortaya çıkarır. Tabaklamadan önce etleme ve mekanik işlemlerle deriden uzaklaşır.

2.2. DERİNİN KİMYASAL YAPISI

Hayvan derisi proteinler, az miktarda yağ ve mineraller ile fazla miktarda sudan oluşur. Bu maddelerin her birinin payı derinin türüne, ırka, yaşa, cinsiyete ve yaşam koşullarına göre değişir⁵.



Şekil 2. 2: Derinin Kimyasal Yapısı

⁵ (Wikipedia,2011)

2.3. DERİ ÇEŞİTLERİ

Birçok deri çeşidi bulunmaktadır. Bunlara örnek olarak küçükbaş, büyükbaş ve av hayvanlarını verebiliriz. Tabiki daha farklı deri çeşitleri mevcuttur. Aşağıda bir kaç türün resimleri bulunmaktadır.



Şekil 2. 3: Küçük Baş



Şekil 2. 4: Büyük Baş Hayvanlar



Kanguru

Tilki

Fok

Karaca


Şekil 2. 5: Av Hayvanları

2.4. DERİ KALİTESİNİ ETKİLEYEN FAKTÖRLER

Bir hayvan derisinin kalitesi menşesine (geldiği yer), yaşam koşullarına, beslenmelerine, cinsiyetine, türüne ve yaşına göre değerlendirilir. Bunların dışında başka nedenlerden dolayı da hata ve kusurlar oluşabilir.

2.5. DERİ DURUMU

Derinin çeşitli vücut bölgelerine göre kalınlık farklılıkları vardır. İyi durumlu bir deri kenarlarda ve kenar bölgelerde orta bölgelerdeki kalınlığa sahiptir.



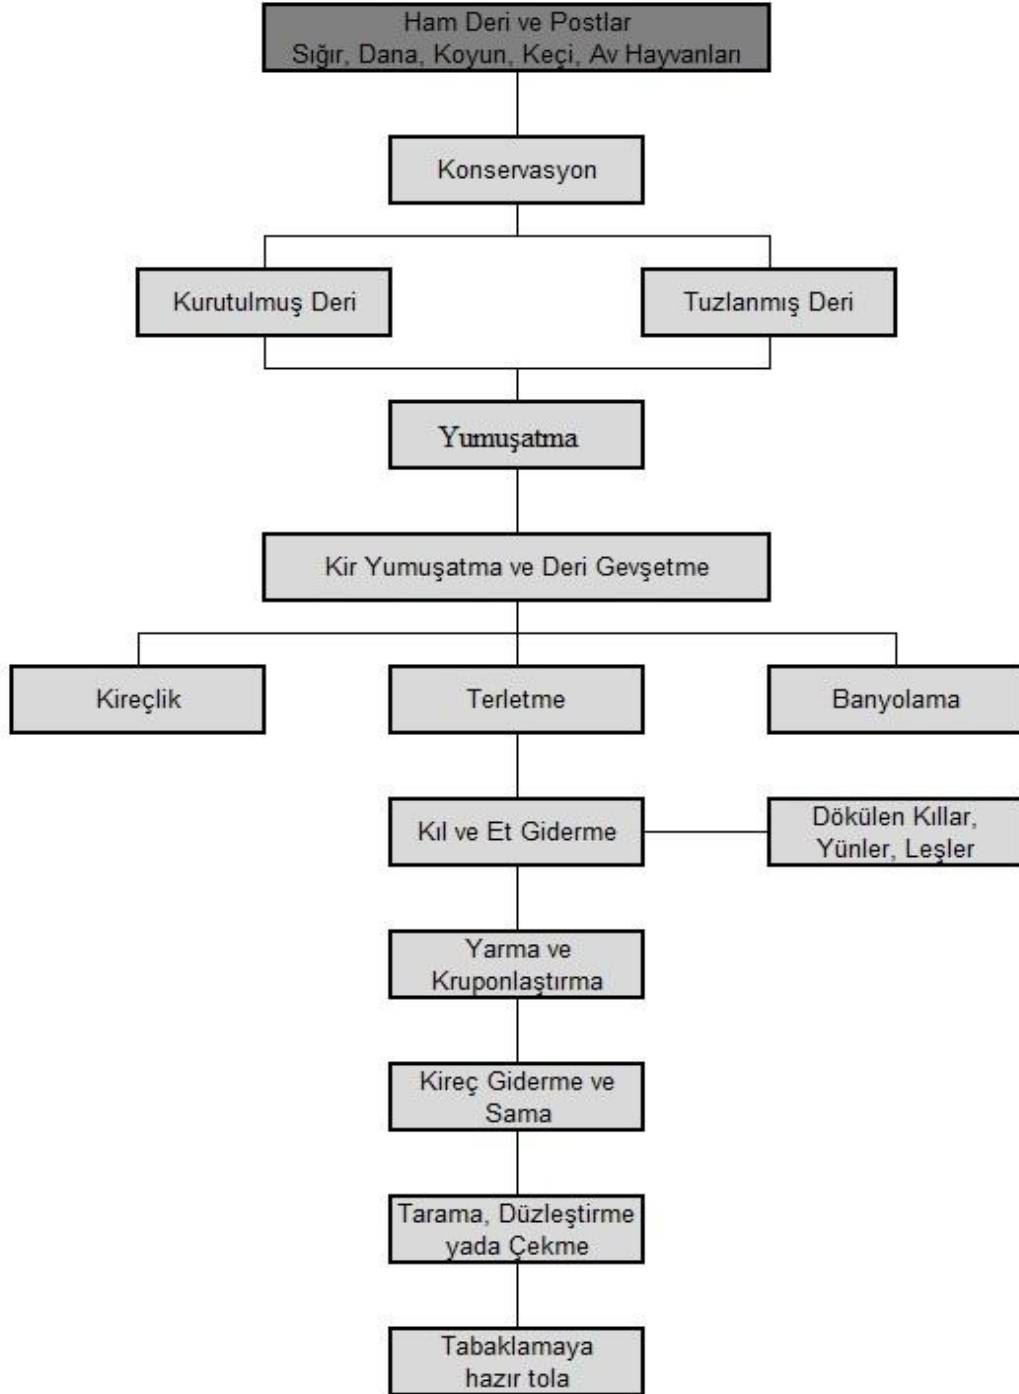
Şekil 2. 6: Derinin Kısımları

Krupon (Croupon); bütün deri ve post türlerinde deri imalatı için en uygun bölümdür. Çünkü burada deri dokusu birbirine sıkı bağlarla bağlı kuvvetli ve düzgün bir görünümündedir. Boyun bölgesine doğru deri boyundan veya besi katlarından dolayı düzgün olmayan bir görünüm alır. Karın ve bacak bölgelerinde deri daha zayıf ve incedir.

2.6. DERİ İŞLEME

Elde edilen ham deri ve postların mamul deriye dönüştürülmeleri için tabaklanmaları zorunludur. Ham derinin mamul deriye dönüştürülmesi sırasında post veya ham derinin esas yapısı bozulmadan çeşitli işlem basamakları uygulanır.

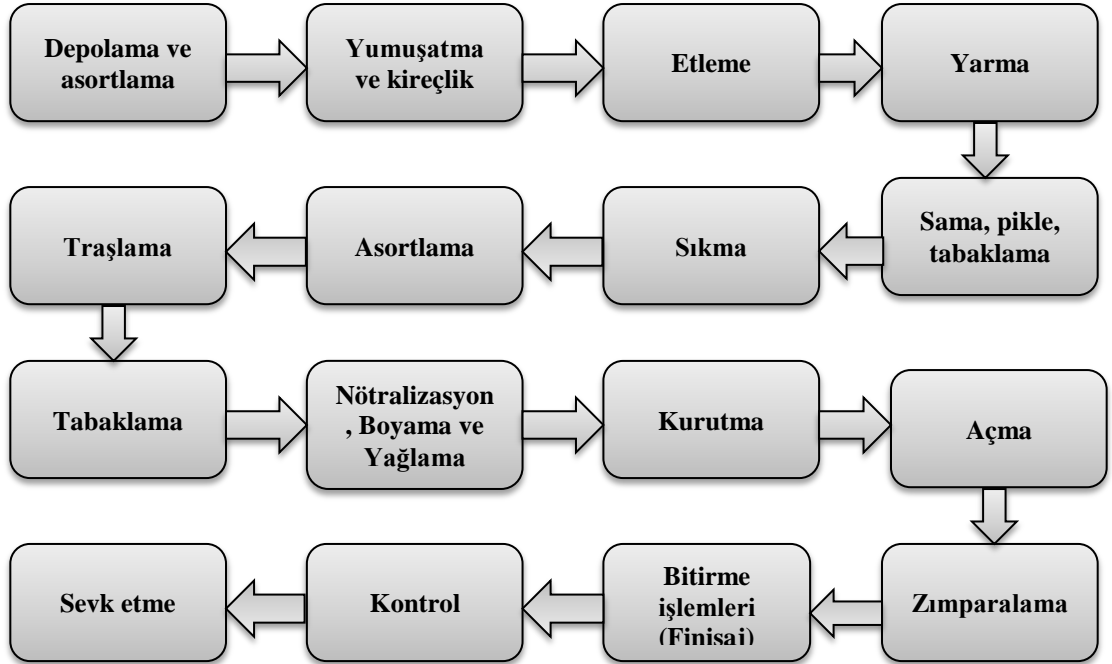
Ham Deriyi Tabaklamaya Hazırlama



Şekil 2. 7: Ham Deriyi Tabaklamaya Hazırlama

2.7. DERİ ÜRETİM AŞAMALARI

Mamül deriler bir takım işlemlerden geçerek üretim aşamasına gelmektedirler. Bu işlemlerden geçtikten sonra giysilik deri üretim firmalarına sevk edilmektedirler. Sevk edilen deriler kesim öncesinde asorti dediğimiz işlenmiş hayvansal derilerin eşleştirmesi kısmına gelmektedirler. Burada kesim ustası en yakın olarak benimsediği derileri bir biri ile eşleştirerek gruplamış olduğu derileri kesime hazır hale getirmektedir.



Şekil 2. 8: Deri Üretim Aşamaları

2.8. İŞLENMİŞ DERİ ÖRNEKLERİ

İşlenmiş hayvansal deriler istenilen renk tonlarında boyanabilmektedir. Bunlara örnek olması bakımından aşağıda bazı işlenmiş deri örnekleri verilmektedir.



Şekil 2. 9: İşlenmiş Deri Örnekleri

3. YAPAY SİNİR AĞLARI (YSA)

3.1. Yapay Sinir Ağlarının (YSA) Genel Tanımı

Yapay Sinir Ağları (YSA) insan beyninin çalışmasından esinlenerek tasarlanmış olup çok daha basit bir yapıya sahip olmasından dolayı anlaşılmasında daha kolaydır. YSA biyolojik sinir sisteminin bilinen temel özelliklerini benzetmek üzere geliştirilmiştir. Benzetilen sinir hücreleri nöronlar içerirler ve bu nöronlar çeşitli şekillerde birbirine bağlanarak ağı oluştururlar. Oluşturulan ağlar öğrenme, belleğe alma ve veriler arasındaki ilişkiyi meydana getirme yeterliliğine sahiptirler. İnsanların geçmişte yaşadıklarından ders çıkarma, tecrübe kazanma gibi YSA'da da öğretilen bilgiden sonuç çıkarılması sağlanmaktadır. YSA mimarilerinin çeşitliliğine rağmen, benzer kısımlardan oluşurlar. Bir sinir ağının genel formunda, nörona benzeyen birime işlem elemanı denilir. YSA, katmanlar biçimde düzenlenen basit işlem elemanı gruplarından oluşmaktadır. Bütün katmanlar farklı ağırlık değerlerine sahip olan araçlarla iletişimde bulunduğu işlem elemanını içermektedir. YSA'nın oluşturulmasında hücrelerin karşılıklı bağlantı biçimleri ya da işlem elemanlarının düzenlenmesi, bilgi, öğrenme ve bilgiyi kullanma yöntemi olarak üç temel gereksinim vardır⁶.

3.2. YSA' ların Temel Özellikleri

Problemlerin çözümlenmesini öğrenen bilgisayarlardır. Öğrenme biçimine ve örnek verilere dayalı olarak problemler çözümlenir. Uzmanların bilgilerine gerek duyulmamaktadır. Farklı örnekleri ayırt etmek için önemli özellikleri ve bağlantıları kendi içlerinde eğitilirler. Örnek veriler ile veya gerçek verilerle öğretilirler. Yeterli yeteneklerde uygun mimariye ve öğrenme yapısına gereksinim duymaktadırlar.

⁶ Karlık, Ders Notları, 2009-2010

3.3. YSA' nın Avantaj ve Dezavantajları

Yapay sinir ağlarında veriler ağı bütününde saklı tutulur ve bilgi işleyişleri programlamalara nazaran daha farklıdır. Yapay sinir ağını kullanan kişilerin algoritmayı bilmeleri gerekmez çünkü verileri tek çözüm üretecek şekilde hazırlamaları gerekir. Yapay sinir ağları ile bir çok probleme çözüm bulmak mümkündür ancak önemli olan kısmı donanımın güçlü olmasıdır. Donanın ne kadar kuvvetli olursa problemlerin çözümleri o nispette çabuk çözüme ulaşır. Bunun sebebi yapay sinir ağlarının yapısının paralel bir düzende olmasından kaynaklanmaktadır. Karmaşık olan kararlar kendi içerisinde üretilmektedir ve hata oranları kendiliğinden oluşturulmaktadır. Dağıtık bellek bulunmaktadır ve dereceli bozulma gösterirler. Eksik bilgilerle çalışabilmektedirler. Hata temizlemede başarılıdırlar.

YSA'nın avantajlarının yanında dezavantajları da bulunmaktadır. Her işlemsel problemlerde kullanılamaz. Eğitim ve test verileri olması gerekir. Donanıma bağlı olarak problem çözümlerinde zaman sorunu yaşanabilir. Ağ yapısının belirlenmesi belli kurallara dayalı değildir. Ağı eğitiminin ne zaman biteceği belirsizdir. YSA uygulamaları çözümlenemeyen problemlere çözüm oluşturmaktadır ancak algoritma, yazılım geliştirme, doğrulama ve gerçekleştirme süresi ve maliyeti yüksektir.

3.4. YSA' nın Kullanıldığı Alanlar

- Çoklu algılayıcı verilerinin kaynaştırılması,
- Doğrusal olmayan sistem modelleme,
- İyileştirme süreçleri,
- Karar oluşturma,
- Kontrol,
- Medikal tanımlama,
- Optimizasyon,
- Örüntü tanıma,
- Robot denetimi,
- Sınıflandırma,
- Sinyal filtreleme,

- Uyarlamalı işaret işleme,
- Veri sıkıştırma,
- Zaman serileri analizleri,

YSA önceleri Elektrik - Elektronik mühendisleri ile matematikçiler tarafından kullanılmaktaydı. Zamanla tüm mühendislik dallarında ve birçok uygulama alanlarında kullanılmaya başlanmıştır. Bu alanlardan bazıları şunlardır; dil, finans, güvenlik, otomotiv, sağlık, savunma, telekomünikasyon, uzay, üretim, vs.

3.5. YSA' nın Gelişimi

Günümüz bilgisayar sistemleri sayısal işlemler alanında insan beynine göre çok daha hızlı ve hatasız işlemler yapmaktadır. Ancak zeka ve tecrübe isteyen işlemlerde başarısız kalmaktadırlar. Bir çok araştırmacı uzun yıllardır bu alan üzerine çalışmalarını sürdürmektedirler. İnsan sinir sisteminin anlaşılması için nöronların fonksiyonları ve bağlantılarını test etmek için matematiksel modellerin geliştirilmesi sağlanmıştır. Oluşturulan bu modeller insan beyninin fonksiyonlarını taklit etmesinin yanında faydalı fonksiyonları da oluşturdukları belirlenmiştir.

1940'lerde Mc Culloch ve Pitts, bir biyolojik nöronun temel fonksiyonlarının basit bir eşik cihazı olarak modellenebileceğini göstermiştir⁷. 1949'da Donald Hebb ise "The Organization of Behaviour" adlı kitabında hücrese seviyede beyinin öğrenme mekanizmasından bahsetmiştir⁸. Hebb' in biyolojik öğrenme kuralına göre; bir nöronun dendrit (Şekil 3.1) yoluyla gelen ve bir akson yoluyla alınan giriş onun bir darbe üretmesine sebep olur. Sonraki aksonal girişlerin darbe üretmesi olasılığı artar. Böylelikle yapılan davranışın mükâfatı ortaya çıkar.

Hızlı hesaplama yönelik ilk YSA çalışmaları 1950'li yıllarda başlamıştır. Basit nöron modellerine dayalı bir hesaplama modeli, 1950'lerde Frank Rosenblatt tarafından önerilmiş⁹ ve ardından perceptron diye bilinen tek katmanlı ilk YSA modeli (Şekil 3.2) ortaya çıkmıştır¹⁰. 1960'lı yıllarda Widrow ve Hoff, bu basit

⁷ Mc Culloch, W.S., Pitts, W.H. 1943. *A logical calculus of the ideas immanent in neural nets*. Bull. Math.Biophys. 5:115-133.

⁸ Hebb, D.O. 1949. *The Organization of Behaviour*, John WileySons, New York.

⁹ Rosenblatt, F. 1959. *Principles of Neuradynamics*, Spartan Books, New York.

¹⁰ Rosenblatt, F. 1962. *Principles of Neuradynamics:Perceptrons and The Theory of Brain Mechanisms*, Spartan Books, Washington D.C.

nöron modellerini kullanarak öğrenebilen ilk adaptif sistemler üzerinde çalışmış ve delta kuralı diye bilinen; gerçek çıkış ile istenen çıkış arasındaki farka eşit bir hata terimi kullanarak bağ ağırlıklarının değiştirildiği bir öğrenme kuralını ortaya koymuşlardır ¹¹.

1969'da Minsky ve Papert, basit perceptron modelinin, yalnızca örnek sınıflarının lineer bir sınırla ayrılabilirdiği örneklemeleri sınıflandırabildiğini; ancak bu modelle, klasik XOR problemine çözüm bulmanın imkânsız olduğunu göstermişlerdir. Çalışmalarında YSA yardımı ile öğrenme ve hesaplamada aşılması zor engeller olduğunu iddia etmişler ve bu iddiaları ile YSA konusundaki çalışmalarını önemli derecede yavaşlatmışlardır ¹².

1969-1982 yılları arasındaki çalışmalarda ise teori artık oturmuş ve 1982'de J.J. Hopfield tarafından yayınlanan "Neural Networks and Physical Systems" adlı çalışma ile çağdaş YSA devri başlamıştır ¹³. Bu çalışmada Hopfield, nöronların karşılıklı etkileşimlerine dayanan bir nöral hesaplama modeli önermiştir. Bu model, bir enerji fonksiyonunu, alabileceği en az değerine indiren 1. mertebe lineer olmayan diferansiyel denklemlerden oluşmuştur. Hopfield; ağ seviyesinde, tek tek nöron seviyesinde var olmayan hesaplama kapasitesinin bulunduğunu öne sürmüştür. Bu tür YSA ya, "Hopfield Ağı" denilmektedir. Hopfield'in geri beslemeli YSA modelini ortaya atması ¹⁴ ve bunun pratik Geliştirilecek Sistem optimizasyon problemlerinde kullanılabilirliğini göstermesi (Hopfield 1985), YSA konusundaki çalışmalarını yeniden hızlandırmıştır.

1986'da Grossberg, ART yani Uyarlanabilir Rezonans Teorisi (Adaptive Resonance Theory) adında bir YSA yapısını geliştirmiştir ¹⁵. ART çok gelişmiş bir YSA modeli olmakla beraber henüz çok fazla probleme uygulanmamıştır. O sıralarda Kohonen'de "kendi kendini düzenleyen nitelik haritasını (selforganizing maps)

¹¹ Widrow, B., Hoff, M. 1960. *Adaptive switching circuits*. IRE WESCON Convention Record 4:96-104.

¹² Minsky, M. ve Papert, S. 1969. *Perceptrons: An introduction to Computational Geometry*, MIT Press, Cambridge, MA.

¹³ Hopfield, J.J. 1982. *Neural networks and physical systems with emergent collective computational abilities*. *Proc.Nat.Acad.Sci* 79:2554-2558.


¹⁴ Hopfield, J.J. 1987. Learning algorithms and probability distributions in feed-forward and feed back networks. *Proc.Nat.Acad.Sci* 88:8429-8433

¹⁵ Grossberg, S. 1986. *The Adaptive Brain I: Cognition, Learning, Reinforcement, and Rhythm, and The Adaptive Brain II: Visions, Speech, Language, and Motor Control*, Elsevier/North-Holland, Amsterdam.

geliştirmiştir ¹⁶. Bu YSA modeli, nümerik aerodinamik akış hesaplamaları için çoğu algoritmik yöntemden daha etkili olmuştur.

1986'da Rumelhart ve arkadaşları "Parallel Distributed Processing" (paralel dağılımlı işleme) adlı kitaplarında, ileri beslemeli (feed-forward) ağlarda yeni öğrenme modeli olan hatanın geriye yayılması algoritmasını (backpropagation algorithm) geliştirerek, daha önce bu konuda Minsky ve arkadaşları tarafından iddia edilen aksaklıkların aşılabileceğini göstermişlerdir ¹⁷. Bugün endüstride birçok YSA uygulamasında bu öğrenme yöntemi ile bunun değişik varyasyonları kullanılmaktadır. Back-propagation algoritması, kullanımı çok yaygın olan ve öğrenilmesi kolay bir ağıdır.

3.6. Biyolojik Nöron ve Yapay Sinir Modeli



Şekil 3. 1: Biyolojik sinir hücresinin yapısı

Sinir sisteminin temel yapıtaşı olan nöronlar uyarılara kasılarak yanıt verirler. Nöron, soma adı verilen hücre gövdesi dentrit denilen kıvrımlı uzantılar ve somanın dalları sayesinde nöronu dallarına bağlayan tek sinir fiberli aksondan oluşur. Dentritler hücreye gelen girişleri toplarlar. Dentrit tarafından alınan işaretler hücrede birleştirilerek bir çıkış darbesi üretilip üretilmeyeceğine karar verilir. Eğer bir iş yapılacaksa üretilen çıkış darbesi aksonlar tarafından taşınarak diğer nöronlarla olan bağlantılara veya terminal organlara iletilir. Fakat korteks, işin yapılabilmesi için hangi nöron harekete geçirilecekse, sadece ona komut gönderir.


¹⁶ Kohonen, T. 1984. Self-Organization and Associative Memory, Springer-Verlag, Berlin.

¹⁷ Rumelhart, D.E., McClelland, J.L., PDP Research Group 1986. Parallel Distributed Processing: Explorations in the Microstructure of Cognition, v. 1: Foundations, MIT Press, Cambridge, MA.

Gönderme tepkisine sinaps adı verilir. Bir sinir hücresine giren sinapslar, o hücrenin özelliklerine göre işlenir ve tek bir çıktı (sinaps) aksondan gönderilir. Her bir sinir hücresi bir eşik değerine sahiptir. Buna eşik (Threshold) değeri adı verilir. Eğer gelen sinapsların toplu bir işlemde geçirdikten sonraki sonuç değerini aşabilirse, ulaşan değer aksondan sinaps olarak gönderilir. Her bir dentritin ağırlık değeri vardır. Gelen bilgi bu ağırlık değeri ile çarpılır (işlenir) ve önemine göre yeni değeri oluşturur ve hedef sinir hücresine yeni değeri ile girer. İki veya daha fazla bilgiler arasındaki bağlar ilişki kurarken, ağırlık değerleri belirlenir. Sinir hücrelerindeki bu değerler, kendi spesifik özelliklerine göre değişir.

Sinapslarla düzeltilen işaretleri taşıyan aksonlar ve dentritlerle iç içe geçmiş nöronlar bir sinir ağı oluştururlar. Şekilde 3.2’ de en basit şekilde nöron modeli, bir eşik birimi olarak algılanabilir. Eşik birimi, çıkışları toplayan ve sadece girişin toplamı iç eşik değerini aştığında bir çıkış üreten işlem elemanıdır.

(Aktif yapma işareti)



Şekil 3. 2: Nöron modeli

Nöron sinapslarında ki işaretleri alır ve hepsini toplar. Eğer toplanan işaret gücü eşiği geçecek kadar güçlü ise diğer nöronları ve dentritleri uyaran akson boyunca bir işaret gönderilir. Kesişen dentritlerden gelen sinapslarla kaplanan bütün işaretleri soma toplar. Toplam işaret daha sonra nöronun iç eşik değeri ile karşılaştırılır ve eşik değeri aşmışsa aksona bir işaret yayar. YSA, bu basit nöronların bağlanarak bir ağ’a dönüştürülmesiyle meydana getirilir¹⁸.

¹⁸ Yagmur D. F.(2008). “Automatic Recognition Of Retinopathy Diseases By Using Neural Network”, Halic University, M.S. , Thesis, Istanbul, Turkey


3.7. YSA' nın Yapısı ve İşlem Elemanı

YSA temel olarak, basit yapıda ve yönlü bir ağ biçimindedir(Şekil 3.4). Her bir düğüm, hücre denilen n. dereceden lineer olmayan bir devredir. Düğümler işlem elemanı olarak tanımlanır. Düğümler arasında bağlantılar vardır. Her bağlantı tek yönlü işaret iletim yolu olarak görev yapar. Her işlem elemanı istenildiği sayıda giriş bağlantısı ve tek bir çıkış bağlantısı alabilir. Fakat bu bağlantı kopya edilebilir. Yani bu tek çıkış, birçok hücreyi besleyebilir. Ağdaki tek gecikme, çıkışları ileten bağlantı yollarındaki iletim gecikmeleridir. İşlem elemanının çıkışı isteğe bağlı olarak reel veya iki tabanlı bir değeri olan herhangi bir matematiksel tipte olabilir.

Kısmen sürekli çalışma konumunda “aktif” halde eleman bir çıkış işareti üretir. Giriş işaretleri YSA ya bilgi taşır. Sonuç ise çıkış işaretlerinden alınabilir. Şekil 3.5'te genel bir işlem elemanı gösterilmiştir. YSA transfer fonksiyonu ve yerel bellek elemanı, bir öğrenme kuralı ile giriş çıkış işareti arasındaki bağlantıya göre ayarlanır. Aktif yapma girişi (bias value) için, bir zamanlama fonksiyonu tanımlanması gerekebilir.

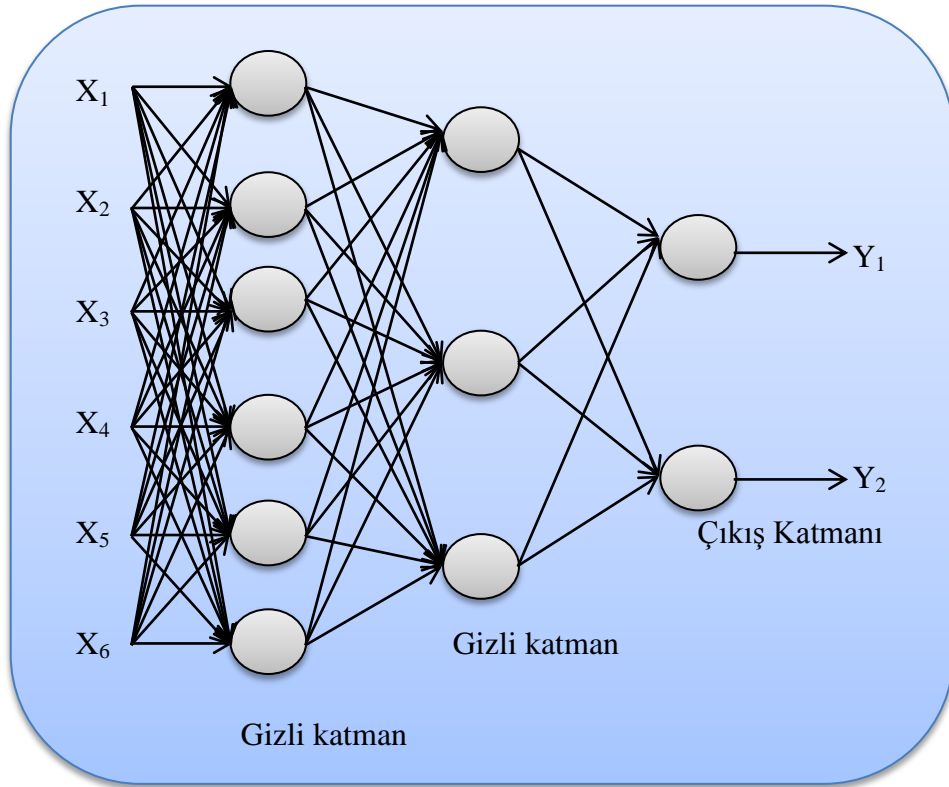
3.8. Giriş İşareti Sınıfları

YSA bir takım alt kümelerle ayrılabilir. Bu alt kümelerdeki elemanların transfer fonksiyonları aynıdır. Bu küçük gruplara “katman” layer adı verilir. Ağ katmanların birbirlerine hiyerarşik şekilde bağlanmasından oluşmuştur. Dış dünyadan alınan bilgi giriş katmanı ile taşınır. YSA transfer fonksiyonu ve yerel bellek elemanı bir öğrenme kuralı ile giriş çıkış işareti arasındaki bağlantıya göre ayarlanır. Aktif yapma girişi için bir zamanlama fonksiyonu tanımlanması gerekebilir. Basit işleme elemanlarından oluşmuş birçok ağın temel yapısı Şekil 3.3'teki tek katmanlı yapıdır.



Şekil 3. 3: Tek Katmanlı YSA

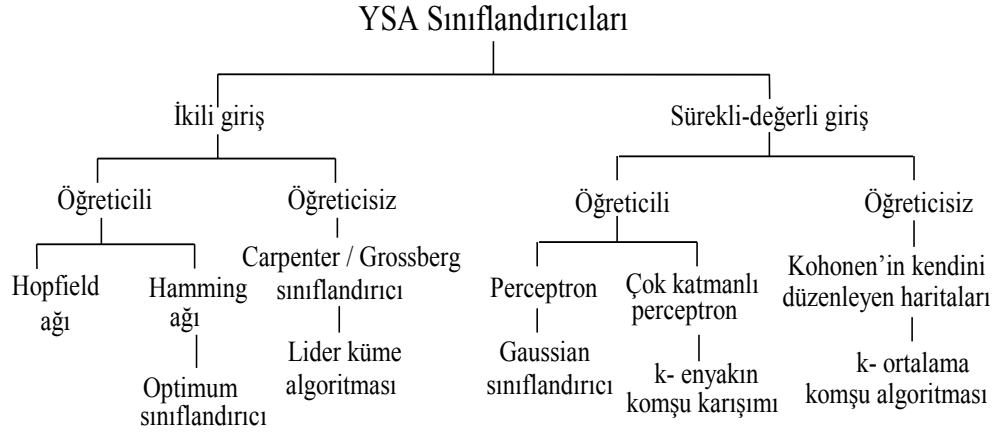
Çok katmanlı ağların çalışma prensibi tek katmanlı ağlar gibidir. Her katmanın çıkışı önceki katmanın çıkışlarından ağırlıklı toplam olarak üretilir. Çok katmanlı YSA Şekil 3.4’de gösterilmiştir. Tek katmanda yapılamayan birçok iş çok katmanlı mimaride başarı ile gerçekleşmiştir.



Şekil 3. 4: Çok katmanlı YSA

3.8.1. YSA Sınıflandırıcıları

Sınıflandırma öncelikle giriş biçimlerine bağlı ikili ve sürekli değerli giriş olmak üzere ikiye ayrılmıştır. Şekil 3.5’de YSA sınıflandırıcılarının genel yapısı şematik olarak belirtilmiştir.



Şekil 3. 5: YSA Sınıflandırıcıları

3.9. Bağlantı Geometrileri

Bağlantılarda, taşınan işaret verisinin cinsi tanımlanmalıdır. Bağlantı geometrisi YSA için çok önemlidir, bağlantı işareti her cinsten olabilir. Bağlantının nerede başlayıp nerede bittiğinin bilinmesi gerekir. 1’den n’e kadar olan bir işlem elemanı kümesinin bağlantıları aşağıda tanımlandığı gibi (n x n) boyutlu matris biçiminde gösterilebilir.

$$[w_{ij}] = \begin{bmatrix} w_{11} & w_{12} & \cdot & \cdot & w_{1n} \\ w_{21} & w_{22} & \cdot & \cdot & w_{2n} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ w_{n1} & w_{n2} & \cdot & \cdot & w_{nn} \end{bmatrix} \quad (3.1)$$

$$w_{ij} = w_{ji} = 1 \quad \Leftarrow \text{i. işlem elemanı j. işlem elemanına bağlı}$$

$$w_{ij} = w_{ji} = 0 \quad \Leftarrow \text{bağlı değil}$$

En fazla n^2 bağlantı olur. Bağlantılar çeşitli geometrik bölgeler arasında demetler halinde düşünülebilir. Bu bağlantı demetlerinde olması gereken kurallar şunlardır:

- 1) Bağlantı demetini oluşturan işlem elemanları aynı bölgeden çıkmalıdır.
- 2) Bağlantı demetinin işaretleri aynı matematiksel tipten olmalıdır.

- 3) Bağlantı demetinin işaretleri aynı sınıftan olmalıdır.
- 4) Bağlantı demetinin bir seçim fonksiyonu (s) olmalıdır.

$\sigma : T \rightarrow 2s$ T : Hedef bölgesi s : Kaynak bölgesi

Hedef bölgesindeki her işlem elemanı, kaynak bölgesindeki her elemana giderse “tam bağlıdır”. Eğer hedef bölgesi elemanı, n adet kaynak bölgesi elemanına bağlı ise “düzgün dağılmış (uniform)” denir. Ayrıca bir elemana, yine bir kaynak elemanı bağlı ise buna “bire-bir bağlı” denir.

3.10. Ağ Tipleri

1- İleri Beslemeli Ağ: Her bir katmandaki hücreler sadece önceki katmanın hücrelerince beslenir ve dolayısıyla bilgi akışı sadece ileriye doğrudur.

2- Kaskat Bağlı Ağ: Hücreler sadece önceki katmanlardaki hücrelerce beslenir.

3- Geri Beslemeli Ağ: En az bir hücre sonraki katmanlardaki hücrelerce beslenir. Bir katmandan diğerine veya kendisine doğru uzanan ağırlıklar yoluyla geri besleme bağlantılarına izin veren daha genel bir ağ yapısı gösterir. Bu çalışmada hem ileri, hem de geri beslemeli (hatanın geriye yayılımı sırasında) ağ tipi birlikte uygulanmaktadır.

3.11. Eşik Fonksiyonları

Transfer veya işaret fonksiyonları olarak da adlandırılan eşik (aktivasyon) fonksiyonları, muhtemel sonsuz giriş kümesine sahip işlem elemanlarından önceden belirlenmiş sınırlar içinde çıkışlar üretirler. Beş tane yaygın olarak kullanılan eşik fonksiyonu vardır. Bunlar liner, rampa, basamak, sigmoid ve $\tanh(x)$ fonksiyonlarıdır. Şekil 3.6’de bu fonksiyonlar gösterilmiştir. Şekil 3.6a’da gösterilen lineer fonksiyonun denklemi aşağıdaki gibidir.

$$f(x) = \alpha \cdot x \quad (3.2)$$

α işlem elemanının x aktivitesini ayarlayan reel değerli bir sabittir. Lineer fonksiyon $(-\tau, +\tau)$ sınırları arasında kısıtlandığında Şekil 3.6b'deki rampa eşik fonksiyonu olur ve denklemi;

$$f(x) = \begin{cases} +\tau & : \text{Eğer } x \geq \tau \text{ ise} \\ x & : \text{Eğer } |x| < \tau \text{ ise (yani } -\tau < x < \tau) \\ -\tau & : \text{Eğer } x \leq -\tau \text{ ise} \end{cases} \quad (3.3)$$

şeklini alır. $+\tau$ / $-\tau$ işlem elemanının maksimumu (minimumu) çoğu zaman doyma seviyesi olarak adlandırılan çıkış değeridir. Eğer eşik fonksiyonu bir giriş işaretine bağlı ise yaydığı $+\tau$ giriş toplamı pozitif, bağlı değilse eşik basamak fonksiyonu $|\delta|$ olarak adlandırılır. Şekil 3.6c, basamak eşik fonksiyonunu gösterir ve denklemi;

$$f(x) = \begin{cases} +\tau & : \text{Eğer } x > 0 \text{ ise} \\ -\delta & : \text{Diğer durumlar} \end{cases} \quad (3.4)$$


şeklindedir. Diğer bir eşik fonksiyonu ise sigmoid fonksiyonudur ve bu tez çalışmasında eşik fonksiyonu olarak kullanılmıştır. Şekil 3.6d'de gösterilen yatık S biçimindeki sigmoid fonksiyonu; seviyeli, doğrusal olmayan(non-lineer) çıkış veren, sınırlı, monoton artan bir fonksiyondur ve denklemi;

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.5)$$

biçimindedir. Son olarak Şekil 3.6e'de ise $\tanh(x)$ fonksiyonu görülmektedir ve denklemi;

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (3.6)$$

şeklindedir. Her işlem elemanı kendisine gelen bir yerel veriye göre, kendisini ayarlayarak bütün YSA'nın bilgi bölgesini öğrenmesini sağlar. Yukarıdaki transfer fonksiyonlarını kullanabilmek için, giriş verilerinin gerçek değerlerinin "0" ile "1" arasındaki bir reel sayıya dönüştürülmesi (normalizasyon) gerekir.



Şekil 3. 6 Sık Kullanılan Eşik Fonksiyonları

4. YSA'DA EĞİTME ve ÖĞRENME

4.1. Giriş

YSA bir problemi çözerken ona göre programlanmasa da o problemi çözmeyi öğrenebilir. Eğitim ve öğrenme tüm sinir ağlarının temelidir. Öğrenme, ağdaki nöron sayısının değişmesi değil nöronlar arasındaki bağlantı ağırlıklarının değiştirilmesiyle sağlanır. Nöronun gelen işarete doğru cevap vermesinde en önemli eleman bağlantı ağırlıklarıdır. Doğru ağırlık değeri öğrenme kuralı ile belirlenir. Öğrenme kuralı bir işlem elemanın örnekleri gördükçe kazandığı tecrübeye göre, ilgili bağlantı ağırlıklarını nasıl değiştireceğini belirleyen algoritmalarıdır. Eğitim, ağın öğrenmesi için bir işlemdir. Öğrenme ise eğitim işleminin neticesidir¹⁹.

4.2. Öğreticili Eğitim (supervised training)

Dışarıdan bir eğitici tarafından ağa müdahale edilir. Eğitici sinir ağının ilgili girdi için üretmesi gereken sonucu sinir ağı sistemine verir. Sinir ağına giriş ve çıkış ikilisinden oluşan örnekler sunulur. Ağ girdi kısmını alır ve o anki bağlantı ağırlıklarının temsil ettiği bilgi ile bir çıktı oluşturur. Bu çıktı olması gereken çıktı ile mukayese edilir ve aradaki hata tekrar ağa aktarılarak ağırlıklar bu hatayı azaltacak şekilde değiştirilir.

4.3. Skor ile eğitim (graded training)

Öğreticili eğitmenin bir benzeridir. Fakat girilen çıkış değerine istenen çıkışı vermek yerine sonuç için bir değerlendirmede bulunur. Çıkış durumuna göre,

¹⁹ Yagmur D. F.(2008). “*Automatic Recognition Of Retinopathy Diseases By Using Neural Network*”, Halic University, M.S. , Thesis, Istanbul, Turkey


“başarılı”, “başarısız” gibi değerlendirmelerle geri besleme bilgisi verilmez. Ağ giriş işaretine göre kendini organize eder. Kontrol uygulamaları için çok faydalıdır.

4.4. Öğreticisiz Eğitim (unsupervised training)

Ağa giriş bilgisi ile ilgili örnekler verilir ve geri besleme bilgisi verilmez. Giriş verileri gruplandırılarak eğitildikten sonra herhangi bir girişin eğitim sınıflarından hangi sınıfa ait olduğunu gösterebilir. Kendini düzenleyen ağ, giriş işaretine göre kendini düzenleyerek organize eder. Buda insanların daha önce görmedikleri bir şey hakkında geçmişteki tecrübelerinden faydalanarak bir tahminde bulunmasıdır. Bu eğitim sınıflandırma ve şekil tanıma problemlerine uygulanabilir.

4.5. Ağırlık Uzayı

YSA’ da öğrenme işlemi, işlem elemanlarının bağlantı ağırlıkları değiştirilerek sağlanır. Bu ağırlıkların ağ modeline göre değiştirilmesi esastır. Her bir işlem elemanın “n” adet gerçek ağırlığı ve N adet işlem elemanı olduğu düşünülür. Ağırlık vektörü N x n boyutlu uzayda yayılır.



Şekil 4. 1: Üç boyutlu uzayda ağırlık vektörünün değişimi

Hata değişimini inceleyen iki değişik kural vardır. Bunlar; hata düzeltme kuralları ve gradyan kurallarıdır. Hata düzeltme kuralları; her bir giriş örneğinde ağırlıkları yenileyerek çıktı hatasını en aza indirmeye çalışırlar. Gradyan kurallarında ise, ağırlıklar yeniden ayarlanarak ortalama karesel hata (mean square error) en aza indirilmeye çalışılır.

Ağırlık vektörü ile çalışan YSA da önemli noktalardan birisi, bir öğrenme kuralı geliştirip, bilgi bölgesi kullanarak, eşik fonksiyonu ile ağırlık vektörü “w” yi, istenilen YSA performansını verecek noktaya yöneltmektir. Genellikle öğrenme

kuralı için bir performans ya da maliyet fonksiyonu tanımlanır. Minimizasyon veya maksimizasyon ile “w” vektörü bulunur. Bir performans çeşidi olarak bilinen, karesel ortalama hata (mean squared error, MSE) şu şekilde tanımlanır.

$$MSE = \frac{\sum (d-o)^2}{n}$$

Amaç, hatayı küçültmeye çalışmaktır. Burada;

d = istenen çıkış değeri (desired value)

o: üretilen çıkış değeri n: örüntü sayısı

4.6. Bellek ve Genelleme

YSA’ da bilgi saklama şekli önemlidir. Bellek, birçok yerel bellek (local memory) oluşturularak dağıtılırlar. Bunlar bağlı oldukları ağırlıklardır ve ağırlık o anki durumunu verir. YSA belleğinin yapısı eksik ve anlaşılmayan türde olsa bile anlamlı bir çıkış üretir. Bu kurala “genelleme” denilir. Çıkışın mantıklı olması ağırlık tipine ve karmaşıklığına bağlıdır.

4.7. Hata Toleransı

Normal sistemlerde az bir değişiklikle bile sistemden cevap alınamaz fakat YSA’ da veriler eksik olsa bile iyi eğitilmiş bir ağırlıkta karar verme devam eder. YSA paralel dağıtılmış parametrelili bir sistem olduğundan her bir işlem izole edilmiş gibi davranır. Yapısal bozukluktan dolayı hiçbir zaman sistem durma eğilimi göstermez. Sistemin hataya karşı toleranslı olması bilgilerin bir yerde değil dağıtık olarak saklanmasından kaynaklanıyor.

4.8. Non-Linear ve Paralellik

Matematiksel olarak çözülmesi zor işlemler YSA ile çözümlenir. YSA’ nın yapısı paralellığe sahip olduğu için birbirinden bağımsız işlemleri aynı anda hızlıca yürütebilir.

4.9. Öğrenme Stratejileri

Genel anlamda sinir ağırlıkları her an için güncellenebileceğinden genel güncelleme ifadesi aşağıdaki gibi verilebilir.

$$w(n+1) = w(n) + \Delta w(n)$$

Bir sonraki adım

Burada $\Delta w(n)$, n anında bulunan $w(n)$ ağırlığına (parametrelerine) ilave edilecek hata düzeltme artırımındır. Δw ' nin nasıl belirleneceği öğrenme yöntemini (öğrenme algoritmasını) verir.

Genellikle bir hata fonksiyonu tanımlanarak bu hataya göre bir ölçüt düşünülür. Bu ölçüte değer fonksiyonu (performans indeksi, performans ölçütü veya performans kriteri) adı verilir²⁰.

Amaç; bu ölçütü, sinir ağı parametrelerine göre en küçük yapan parametreleri bulmaktır.


4.10. Perceptron

Perceptron ağı ilk olarak 1943 yılında Mc Culloch ve Pitts tarafından ortaya atılmış ve 1960'larda sinir ağıları olarak F.Rosentblatt tarafından önerilmiştir. En basit yapay sinir ağı örneği tek katmanlı ve tek sinirli perceptrondur. Bu yapay sinir ağlarının birden fazla girişi ve tek bir çıkışı mevcuttur. Çıkış değeri artı bir veya eksi bir olarak değerlendirilir. Perceptronlar genellikle nesnelere iki ayrı sınıfa ayırmak için kullanılmıştır.


Daha sonra 1960 yıllarında F. Rosenblatt yukarıdaki ağ tipini biraz daha geliştirmiştir. Fakat Minsky ve Papert, bu tek katmanlı perceptronun XOR işlemini gerçekleştiremediğini ispatlamışlardır. Şekil 4.2 ve 4.3'den anlaşılacağı gibi 0'ların bir tarafta, 1'lerin bir tarafta ayrılacağı şekilde bir bölge oluşmamaktadır. XOR gibi 3 veya daha fazla sınıfa ihtiyaç duyulan problemleri çözmek için yapılması gereken işlem ise YSA ya yeni katmanlar eklemektir. Eşik bağlarıyla oluşturulan karar

²⁰ Becerikli Y. , Ders Notları,2007

bölgesi şeklinin karmaşıklığı, sadece eklenmiş olan katmanların sayısıyla sınırlıdır. Şekil 4.4’de gösterildiği gibi içbükey ayrılabilir fonksiyonlar gerçekleştirilebilir²¹.




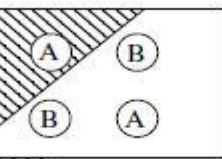
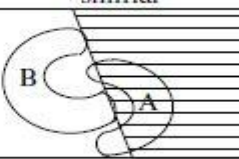
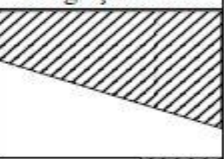

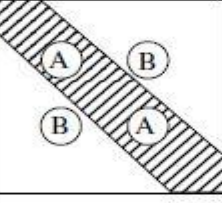
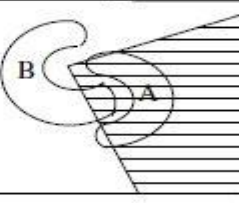
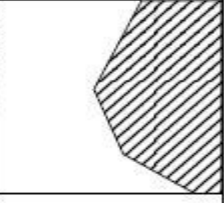

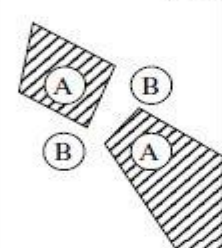
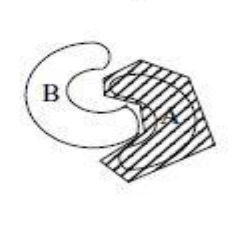
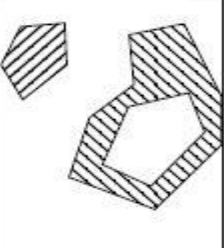
Şekil 4. 2: Tek katmanlı perceptron



Şekil 4. 3: Lineer ayrılabilirliğin gösterimi

Şekil 4.4’ de tek ve çok katmanlı perceptronların sınırlayabileceği (ayırabileceği) karar bölgeleri görülmektedir. Taranmış bölgeler A sınıfına ait karar bölgelerini göstermektedir. Tek katmanlı perceptron, bir düzlemi ikiye ayıran karar bölgeleri oluşturur. İki katmanlı bir perceptron, açık ve kapalı konveks bölgeler oluşturabilir. Üç katmanlı perceptron ise, keyfi derecelerde kompleks karar bölgelerini ayırabilir. Buradan anlaşılmaktadır ki; perceptron gibi ileri yayımlı ağlarda, iki adet gizli katmandan fazlasına gerek yoktur.

²¹ Pao, Y.H. 1989. Adaptive Pattern Recognition and Neural Networks, Addison-Wesley Publishing Co., Reading, Mass.

Yapı	Karar bölgeleri tipi	XOR problemi	Bölgelere dayalı sınıflar	En iyi ayırdığı bölge şekilleri
Tek katman  (a)	Doğrusal ayrıştırabilir, XOR işlevini gerçekleyemez			
İki katman  (b)	Rastgele bölgeler Konveks açık veya kapalı bölgeler			
Üç katman  (c)	Komplekslik derecesi düğüm sayısına bağlı olarak sınırlıdır			

Şekil 4. 4: Tek katmanlı perceptron ile iki ve üç katmanlı bulunan çok katmanlı perceptronların sınırlayabileceği karar bölgeleri (Lippmann 1987)

Üç katmanlı perceptronlarda (giriş katmanı dahil değil) kullanılacak düğüm sayılarının belirlenmesine gelince; karar bölgeleri arasında bağlantı yoksa veya bu bölgeler bir konveks alan ile oluşturulamıyorsa, ikinci katmandaki düğüm sayısı bir den büyük olmalıdır. En kompleks durum için, ikinci katmandaki düğümlerin sayısı, giriş dağılımlarındaki ayrı bölgelerin sayısı kadar olmalıdır. Benzer şekilde birinci katmandaki düğüm sayıları da her bir ikinci katman düğümünce oluşturulan her bir konveks bölge için üç veya daha fazla kenar sağlanacak şekilde yeterli sayıda olmalıdır. Bununla beraber, Gutierrez ve arkadaşları, değişik perceptron ağlarının ihtiyacı olan düğüm sayıları hakkında araştırma yapmışlar ve çok fazla düğümün de, çok az sayıda olduğu gibi zararlı etkisi olduğunu bulmuşlardır²². Tek katmanlı perceptron uygulanan her eğitim seti modelinin en önemli özelliği, lineer biçimde dağılmak zorunda olmasıdır. Eğer bu doğruysa; Rosenblatt, perceptron ağının kararlı olacağını göstermiştir (Örneğin ağırlıklar iterasyonla yakınsar).

²² Gutierrez, W. J., Grandin, R.D. 1989. Estimating hidden units for two layer perceptrons. Proc. of the 1st Int.Conf. on Artificial Neural Networks, London, U.K., October, 120-124.

4.11. Çok katmanlı perceptron(Multi-Layer Perceptron)

Çok katmanlı perceptron giriş ve çıkış katmanları arasında birden fazla katmanın kullanıldığı ileri yayımlı (feed-forward) YSA sistemidir. Gizli katman (hidden layer) olarak isimlendirilen bu ara katmanlarda, düğümleri giriş ve çıkış katmanlarına doğrudan bağlı olmayan işlem elemanları vardır. Çok katmanlı perceptronlar, tek katmanlı perceptronlara ait sınırlamaların birçoğunu ortadan kaldırmalarına rağmen, önceleri etkin eğitme algoritmalarının mevcut olmamasından ötürü uygulamaları yaygın değildi. Ancak yeni eğitme algoritmalarının geliştirilmesi ile bu durum değişmiştir²³.

Çok katmanlı ağlarda, veriler giriş katmanı tarafından kabul edilirler. Ağ içinde yapılan işlemler sonucunda çıkış katmanında oluşan sonuç değer, istenen cevap ile karşılaştırılır. Bulunan cevap ile istenen cevap arasında herhangi bir ayrılık varsa, ağırlıklar bu farkı azaltacak şekilde yeniden düzenlenir. Girişteki değer, ağırlıklar uygun noktaya ulaşana kadar değişmez. Hesaplanan çıkışlar, istenilen cevaplarla karşılaştırılarak sonuçta gerekirse hata belirtilir. Hata işareti gizli işlem elemanlarından çıkış birimine olan ağırlıkları değiştirmekte kullanılır. Ama bunu yaparken giriş katmanından gizli katmana gelenin değiştirilip değiştirilemediğini düşünmek gerekir. Gizli birimlerden ne tür bir çıkış istendiği bilinmeyeceği için gizli birimlerin çıkışında hata işareti verilmesi kolay bir şey değildir. Bunun yerine her birimin çıkış biriminin hatalarına olan etkisi bilinmelidir. Bu ise hatalı birim için gizli birime bağlı olan çıkış birimlerinin hata işaretlerinin toplamı alınarak yapılır.

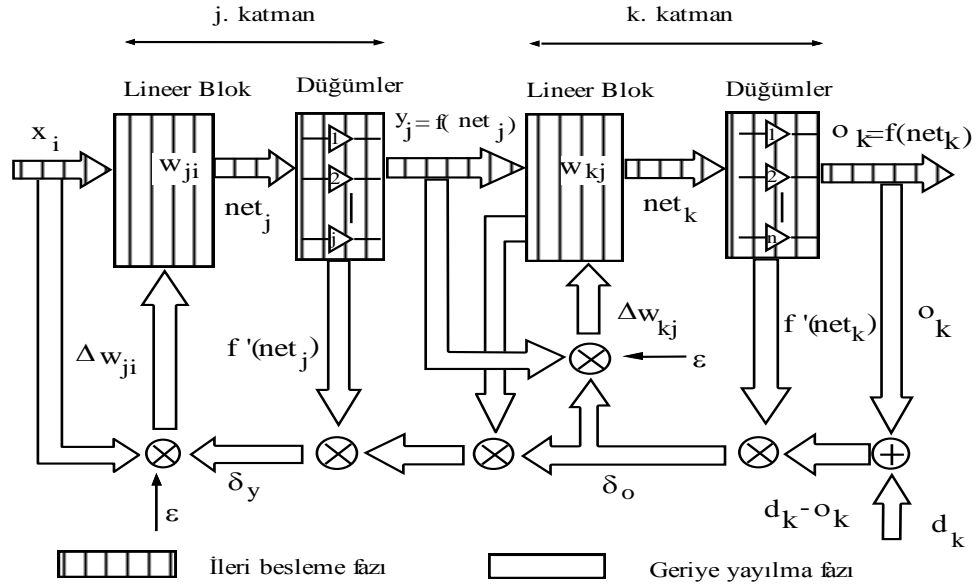
Çok sayıda gizli katmana sahip sistemlerde, her sistemin hata işaretleri, bir önceki katmanın düzeltilmiş işlemlerinden çıkartılarak işlem tekrarlanır. Sonuç olarak, ağırlık düzeltme işlemi çıkış seviyesine bağlı ağırlıklardan başlar ve işlem ters yönde, giriş seviyesine varana kadar devam eder. Sonuçta sistem hatalar yapar, ama bu hatalardan bir şeyler öğrenip isteneni bulana kadar işleme devam eder. Bu yönteme “hatanın geriye yayılması algoritması” (back-propagation algorithm) denilir²⁴.

²³ Rumelhart, D.E., Hinton, G.E., Williams, R.J. 1986. “Learning Internal Representations by Error Propagation”, MIT Press, Cambridge, MA.

²⁴ Rumelhart, D.E., McClelland, J.L., PDP Research Group 1986.

4.12. Hatanın geriye yayılması algoritması ve geliştirilmiş delta kuralı

Hatanın geriye yayılması eğitme algoritması, çok katmanlı, ileri yayımlı bir perceptrondan elde edilen çıkışlar ile eldeki hedef çıkışlar arasındaki hataların karesinin ortalamasını minimum yapmak için geliştirilmiş iteratif bir gradyan algoritmadır ve eğitme işlemi için geliştirilmiş delta kuralını (Generalized DeltaRule) kullanır (Şekil 4.5).



Şekil 4.5: Hatanın geriye yayılması algoritmasının blok diyagramı

Şekil 4.5' de mimarisi gösterilen algoritma, ana hatlarıyla şöyledir: Ağ mimarisi tanımlanır ve ağırlıklar bazı rastgele küçük sayılar ile başlatılarak, ağa ilk giriş sunulur. Burada m-boyutlu giriş örüntüleri girildiğinde; $x_i = [x_1, x_2, \dots, x_m]^T$ dir. Benzer şekilde istenilen n-boyutlu çıkış örüntülerini ise; $d_k = [d_1, d_2, \dots, d_n]^T$ belirtir. x_i değerleri i katmanındaki nöronların çıkış değerleri ise, j katmanındaki bir nörona gelecek olan toplam giriş,

$$net_j = \sum_{i=1}^m w_{ji} \cdot x_i \quad (i. \text{ düğümden } j. \text{ düğüme}) \quad (4.1)$$

olur. Gizli katmandaki j nöronunun çıkışı (transfer fonksiyonu çıkışı);

$$y_j = f_j(net_j), \quad j=1,2,\dots,J \quad (4.2)$$

dir ve burada f_j transfer fonksiyonudur. Çıkış katmanındaki k nöronuna gelecek olan toplam giriş ise,

$$\text{net}_k = \sum_{j=1}^J w_{kj} \cdot y_j \quad (4.3)$$

dir. Yine çıkış katmanındaki bir k nöronun lineer olmayan çıkışı;

$$o_k = f_k(\text{net}_k), k = 1, 2, \dots, n \text{ olur.} \quad (4.4)$$

Ağdan elde edilen çıkış, asıl çıkış ile karşılaştırılır ve e_k hatası aşağıdaki gibi hesaplanır;

$$e_k = (d_k - o_k) \quad (4.5)$$


Burada d_k ve o_k sırasıyla çıkış katmanındaki herhangi bir k nöronunun hedef (istenen) ve ağdan elde edilen (asıl) çıkışlardır. Dikkat edilmesi gereken husus, böyle bir karşılaştırmanın sadece ağın çıkış katmanı için mümkün olmasıdır. Böylece çıkış katmanıyla olan bağlar için ağırlık ayarlaması öncelikle göz önüne alınır. Her bir örüntü (pattern) için toplam karesel hata;

$$E = \frac{1}{2} \sum_k (d_k - o_k)^2 \quad (4.6)$$


olur. Hata fonksiyonu Şekil 4.6 ve 4.7'de gösterildiği gibidir. Gizli katman olduğu zaman; hata düzeyi Şekil 4.6'de olduğu gibi sadece bir minimumdan oluşmaz, Şekil 4.7'deki gibi çeşitli minimumlar oluşur. Bu minimumlar lokal ve global olarak sınıflandırılırlar. Lokal minimumlar birden fazla olabilir. Global minimum, hatanın en küçük olduğu minimumdur. Öğrenme sırasında global minimuma ulaşmak amaçlanır.

Ağırlıkların değişimi;

$$\Delta w_{kj} = -\varepsilon \frac{\partial E}{\partial w_{kj}} \quad (4.7)$$



Şekil 4. 6: Gizli katmanı olmayan ağın hata fonksiyonu



Şekil 4. 7: Gizli katmana ait ağırlık hata fonksiyonu

Burada ϵ , öğrenme oranı katsayısı adı verilen küçük değerde pozitif bir sayıdır (çoğunlukla 0.01 ile 0.9 arasında seçilir). Bu öğrenme oranı, bir sayısal optimizasyon algoritmasındaki adım boyutu parametresine benzemektedir. (4.7)'de eşitliğin sağ tarafı açılırsa (Rumelhart ve ark.1986), şu sonuç elde edilir:

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial w_{kj}} \quad (4.8)$$

$$\frac{\partial net_k}{\partial w_{kj}} = \frac{\partial}{\partial w_{kj}} \sum_j w_{kj} \cdot y_j = \sum_j \frac{\partial w_{kj} \cdot y_j}{\partial w_{kj}} = y_j \quad (4.9)$$

Amaç, uygun w seçimiyle, $E = \sum_p E_p$ toplam hatayı yeterince küçük yapmaktır. Bu amacı gerçekleştirmek için, bir $p \in P$ örüntüsü artarda ve rastgele biçimde seçilir. k . nöronda oluşan ve “delta” adı verilen hata işareti,

$$\delta_o = -\frac{\partial E}{\partial net_k} \quad (4.10)$$

(4.9) ve (4.10)'yi (4.8)'de yerine konulursa,

$$\frac{\partial E}{\partial w_{kj}} = -\delta_o \cdot y_j \quad (4.11)$$

ve, (4.11) ifadesi (4.7)'de yerine konulursa,

$$\Delta w_{kj} = \epsilon \delta_o y_j \quad (4.12)$$

elde edilir. E_p değerini düşürmek demek, ağırlığı $\delta_o y_j$ 'ye bağlı olarak değiştirmek demektir. Buna “Delta kuralı” denir. Önceki gizli katmandaki tüm nöronlar ile çıkış katmanındaki k . nöron arasındaki bağ mukavemetleri, (4.12)'deki Δw_{kj} miktarı ile ayarlanır. (4.10) denklemini kısmi türevlerine ayrılırsa,

$$\delta_o = -\frac{\partial E}{\partial net_k} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial net_k} \quad (4.13)$$

$$\frac{\partial E}{\partial o_k} = -(d_k - o_k) \quad (4.14)$$

olup; k. nöron çıkışının lokal hatasını verir.

$$\frac{\partial o_k}{\partial net_k} = f'_k(net_k) \quad (4.15)$$

Son iki formül (4.13)'de yerine konulursa,

$$\delta_o = (d_k - o_k)f'_k(net_k) \quad (4.16)$$

bulunur. Bu son terim (4.19)'de yerine konulduğunda k nöronu için;

$$\Delta w_{kj} = \varepsilon(d_k - o_k)f'_k(net_k)y_j \quad (4.17)$$

olur. Eğer ağırlıklar çıkış nöronlarını doğrudan etkilemiyorsa (arada gizli katman varsa), (4.12)'e benzer biçimde delta kuralı bu gizli katman için de şu şekilde uygulanır.

$$\begin{aligned} \Delta w_{ji} &= -\varepsilon \frac{\partial E}{\partial w_{ji}} \\ &= -\varepsilon \frac{\partial E}{\partial net_j} \frac{\partial net_j}{\partial w_{ji}} = -\varepsilon \frac{\partial E}{\partial net_j} x_i \end{aligned} \quad (4.18)$$

$$= -\varepsilon \left(-\frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial net_j} \right) x_i = \varepsilon \left(\frac{\partial E}{\partial y_j} \right) f'_j(net_j) x_i$$

$$\Delta w_{ji} = \varepsilon \delta_y x_i \quad (4.19)$$

Bununla birlikte, $\partial E / \partial y_j$ / faktörü doğrudan geliştirilemez. Özel olarak çıkış katmanına etkisi,

$$-\frac{\partial E}{\partial y_j} = -\sum_k \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial y_j} = \sum_k \left(-\frac{\partial E}{\partial net_k} \right) \frac{\partial}{\partial y_j} \sum_m w_{km} y_j = \sum_k \left(-\frac{\partial E}{\partial net_k} \right) w_{kj} = \sum_k \delta_o w_{kj}$$

şeklinde bulunur. Bu durumda;

$$\delta_y = f'_j(net_j) \sum_k \delta_o w_{kj} \quad (4.20)$$

olur. Kısaca özetlenecek olursa; (4.19) formülü şayet j. nöron, çıkış katmanı nöronuysa (4.16)'e benzer biçimde,

$$\delta_y = (d_y - o_y)f'_j(net_j) \quad (4.21)$$

olur. Eğer j nöronları gizli katmana ait nöronlar ise, o zaman (4.11) denklemi kullanılır. Transfer (eşik) fonksiyonu olarak sigmoid fonksiyonu kullanıldığında,

$$f(\text{net}_j) = y_j = \frac{1}{1 + e^{-\text{net}_j}} \quad (4.22)$$

olur. Bu ifadenin türevi alınıp, gerekli sadeleştirme yapıldığında,

$$f'(\text{net}_j) = \frac{1}{1 + e^{-\text{net}_j}} \frac{1 + e^{-\text{net}_j} - 1}{1 + e^{-\text{net}_j}} \quad (4.23)$$

$$\frac{\partial y_j}{\partial \text{net}_j} = y_j(1 - y_j) \quad (4.24)$$

bulunur. Benzer işlem k katmanı için de yapılırsa;

$$\frac{\partial o_k}{\partial \text{net}_k} = f'_k(\text{net}_k) = o_k(1 - o_k) \quad (4.25)$$

elde edilir. (4.25) denklemini (4.16)'de, (4.24) denklemini de (4.20)'de yerine konursa, (4.16) ve (4.20)'daki delta ifadeleri aşağıdaki gibi olur. (δ_o çıkış katmanı, δ_y : gizli katman elemanları içindir);

$$\delta_o = (d_k - o_k)o_k(1 - o_k) \quad (4.26)$$

$$\delta_y = y_j(1 - y_j) \sum_k \delta_o w_{kj} \quad (4.27)$$

w_{ji} yi öğrenme durumunda her eğitme örüntüsünün seti için Δw_{ij} yi hesaplamak gerekir. Öğrenme oranı ε , hızlı öğrenmeyi sağlar; fakat dalgalanmalara sebep olabilir. Rumelhart ve McClelland (1986), (4.17) ve (4.19) ifadelerine bir tür momentum terimi dahil ederek bir değişim öngörmüşlerdir. Bu durumda;

$$\Delta w_{ji}(n+1) = \varepsilon \delta_y x_i + \alpha \Delta w_{ji}(n) \quad (4.28)$$

$$\Delta w_{kj}(n+1) = \varepsilon \delta_o y_j + \alpha \Delta w_{kj}(n) \quad (4.29)$$

olarak yazılabilir. Burada n, öğrenme döngülerinin (iterasyon) sayısını gösterir. Momentum terimi olan α , küçük değerde pozitif bir sayıdır²⁵.

²⁵ Karlık B., Ders Notları,2009-2010

4.13.Öğrenme ve Momentum Katsayıları


YSA ile ilgili bir başka sorun da, düzgün bir öğrenme katsayısının (ϵ) ayarlanmasıdır. Ağırlıkları çok yüksek tutmak davranışın bozulmasına sebep olabilir. Öğrenme katsayısını böyle bir davranışı önlemek için küçük tutmak gereklidir. Öğrenme katsayısı, $0.01 < \epsilon < 10$ aralığında seçilen sabit bir sayıdır. Öte yandan, çok küçük bir öğrenme oranında, öğrenme işleminin yavaşlamasına yol açar.

Momentum (α) fikri bu noktadan hareketle ortaya atılmıştır. Momentum mevcut delta ağırlığı üzerinden önceki delta ağırlığının belirli bir kısmını besler. Böylece daha düşük öğrenme katsayısı ile daha hızlı öğrenme elde edilir. Momentum katsayısı genellikle $0 < \alpha < 1$ aralığında değişen bir sayıdır.

Hatanın geriye yayılması algoritması genellikle iyi bir performans göstermesine rağmen; bu algoritma, bir gradyan arama tekniği olduğu için, global minimum yerine, en küçük kareler (Least Mean Square) fonksiyonunun bir lokal minimumunu bulabilmektedir. Performansı artırmak ve lokal minimum problemini azaltmak için; gizli düğümler ilave edilmesi, ağırlıkların ayarlanması için kullanılan öğrenme katsayısının azaltılması ve farklı rastgele ağırlık setlerinden başlayarak birçok defa eğitime işleminin tekrarlanması öneriler arasındadır²⁶.

Hatanın geriye yayılması algoritması, karesi alınmış hata fonksiyonunu minimize eden kodlu bir algoritma olup ve genelleştirilmiş delta kuralını eğitime için kullanmaktadır. Bu YSA modelinin eğitime işleminin akış diyagramı, Şekil 4.8 de verildiği gibidir.

²⁶ Karlık B., 1994, "Myoelectric Control of Multifunction Prosthesis Using Neural Networks", Yıldız Technical University, PhD, Thesis, Istanbul, Turkey



Şekil 4. 8: Hatanın Geriye Yansımaları Algoritmasının akış diyagramı

5. YAPAY SİNİR AĞI İLE DERİ YÜZEYİ VE RENK TONU SINIFLANDIRMA UYGULANMASI




Şekil 5. 1: İşlenmiş Hayvansal Derinin Sınıflandırılması

İşlenmiş hayvansal derilerin algılayıcılar (fotoğraf makinası, homojen ışık ortamı sağlanmış kapalı alan içerisindeki kamera, tarayıcı) sayesinde elde edilerek, bir takım ön işlemden (dc-seviye, filtre, iyileştirme, edge detection) geçirilerek öz nitelik vektörü elde edilir. Elde edilen bu özellikler bir sınıflandırıcı (YSA, Bulanık mantık, Bayes) sayesinde sınıflandırılır. Şekil 5.1' de işlenmiş hayvansal derinin sınıflandırma aşamaları gösterilmiştir.

5.1. İşlenmiş Hayvansal Derilerin Elde Edilmesi

Uygulamada kullanılan işlenmiş hayvansal deriler Derma Deri Tic. ve San. Ltd. Şti. yetkilileri tarafından temin edilmiştir. Bu işlenmiş hayvansal deriler ilk önce homojen ışık ortamı sağlanmış düzende çekilmiş fakat karşılaşılan hatalar sonucunda bu yöntemden vaz geçilerek tarayıcı ortamında görüntülerin elde edilmiştir. Ancak görüntülerin daha iyi sonuçlar vermesi için profesyonel fotoğraf makinesi ile alınan görüntüler bu tez çalışmasında kullanılmıştır. Yöntem gereği Şekil 5.2 deki gibi 2000 x 2000 24bit RGB haline getirilmiştir.




Şekil 5. 2: İşlenmiş Hayvansal Derinin Normal Boyutu

Matlab'ın resize özelliği kullanılarak normal işlenmiş hayvansal derinin boyutları Şekil 5.3 de görüldüğü gibi 20x20 lik matris boyutuna düşürülür.



Şekil 5. 3: Küçültülmüş İşlenmiş Hayvansal Deri

Resize edilen işlenmiş hayvansal deriler Matlab programında Şekil 5.4 de görüldüğü gibi rgb (red, green, blue)' den gray (gri seviye)' ye dönüştürülür²⁷.



Şekil 5. 4: Gri ye Dönüştürülmüş İşlenmiş Hayvansal Deri

5.2. Öznitelik Çıkarma

Örüntüye ait özelliklerin vektör olarak elde edilmesine öznitelik çıkarımı denir.

Çeşitli öznitelik vektörü çıkarma yöntemi bulunmaktadır. Bunlar örüntüye en uygun olanına göre kullanılır.

- Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform)
- Ayırık Kosinüs Dönüşümü (Discrete Cosine Transform)
- Ayırık Fourier Dönüşümü (Discrete Fourier Transform)
- Zaman Serileri Analizi (Time Series Analysis)

5.2.1. Discrete Wavelet Transform (Ayırık Dalgacık Dönüşümü)

Görüntü işleme için frekans ortamında yapılan filtreleme Fourier Dönüşümü kullanılarak gerçekleştirilir. Fourier Dönüşümü bir görüntüyü sinüs ve kosinüs parçalarına ayırmak için kullanılan önemli bir görüntü işleme aracıdır. Fourier açılımındaki en büyük dezavantaj sadece frekans verisinin olması fakat zaman bilgisini içermemesidir. Bu nedenle bir görüntüde gerek duyulan bütün frekanslar

²⁷ Alasdair McAndrew ,An Introduction to Digital Image Processing with Matlab Notes for SCM2511 Image Processing 1, Page 31-32,Semester 1, 2004

gösterilebilmekte fakat bu frekans değerlerinin ne zaman elde edildiği belirtilmemektedir.

Bu problemi çözmek için geçmiş yıllarda zaman ve frekans bilgisini aynı anda gösteren çeşitli çözümler üretilmiştir. Bu probleme bulunan en son çözüm ise dalgacık dönüşüm tekniğinin kullanılmasıdır.

Dalgacık, bölümlenme(decomposition) tekniklerine dayanan sinyal işlemeden türetilmiştir. Dalgacık dönüşüm tekniğinin arkasındaki düşünce; sinyali çeşitli bölümlere ayırmak ve ayrı ayrı analiz etmektir. Bir sinyalin bu şekilde analiz edilmesi ile o sinyaldeki frekansların ne zaman ve nerede oluştuğuna dair daha fazla bilgi alınabilir. Dalgacık dönüşümü zaman ve frekans gösterimini destekler.

Dalgacıklar, veri veya fonksiyonların gösterimde kullanılan belirli matematiksel gereksinimleri karşılayan fonksiyonlardır. Bir sinyaldeki özelliklerin belirlenmesi için gerekli olan zaman ve frekans verilerinin içermesi ve çoklu çözünürlük analizine dayanması dalgacık kullanımının en önemli sebepleridir.

Görüntü işleme amaçlı kullanılan Ayrık Dalgacık Dönüşümünde ise, sinyali analiz etmek için farklı frekanslar kullanılır. Sinyal yüksek frekansı analiz etmek için bir dizi alçak geçiren filtreden geçirilir.

Görüntüler iki boyutlu veriler olduğu için görüntü sıkıştırma işleminde 2D Ayrık Dalgacık Dönüşümü (DWT) kullanılır. 2D Ayrık Dalgacık Dönüşümünde veri ilk önce satırların sonra da sütunların dönüşümü yapılabilecek şekilde ayrılabilir bir dönüşümdür.

Bu tezde DWT (Discrete Wavelet Transform) ile öznitelik vektörü elde edilmiştir.

Matlab'ın Wavelet toolbox'ından yararlanılarak işlenmiş hayvansal deri resimlerine alçak geçiren ve yüksek geçiren filtre uygulanmıştır²⁸.

Sözdizimi : $[cA,cH,cV,cD] = \text{dwt2}(X,'wname')$

$[cA,cH,cV,cD] = \text{dwt2}(X,Lo_D,Hi_D)$

Dwt2 ile iki boyutlu dalgacık dönüşümü yapılırken ayrıntılar bu isimde (X,'wname') veya dalgacığın ayrıştırıcı filtrelerinde (X,Lo_D,Hi_D) belirtilir.

$[cA,cH,cV,cD] = \text{dwt2}(X,'wname')$

cA da tahmini bir katsayı hesaplar, ayrıntılı olarak cH'da yatay, cV'de dikey, cD'de köşegen matrisi elde edilir. $[cA,cH,cV,cD] = \text{dwt2}(X,'wname')$ daha sonra

²⁸ R. Gonzalez and R. Woods. Digital Image Processing. Addison-Wesley Press, 1993.

elde edilen matrislere Lo_D low_pass filter (alçak geçirgen filtre) ve Hi_D high_pass filter (yüksek geçirgen filtre) uygulanarak iki boyutlu dalgacığın dönüşümü elde edilmiş olur.

İşlenmiş hayvansal derilerin küçültülerek 20x20 lik oluşturulan matris iki boyutlu dalgacık dönüşümü yapıldıktan sonra 10x10 lük matrise dönüşmüştür. Normalize edilmeden önceki matris görünümü;

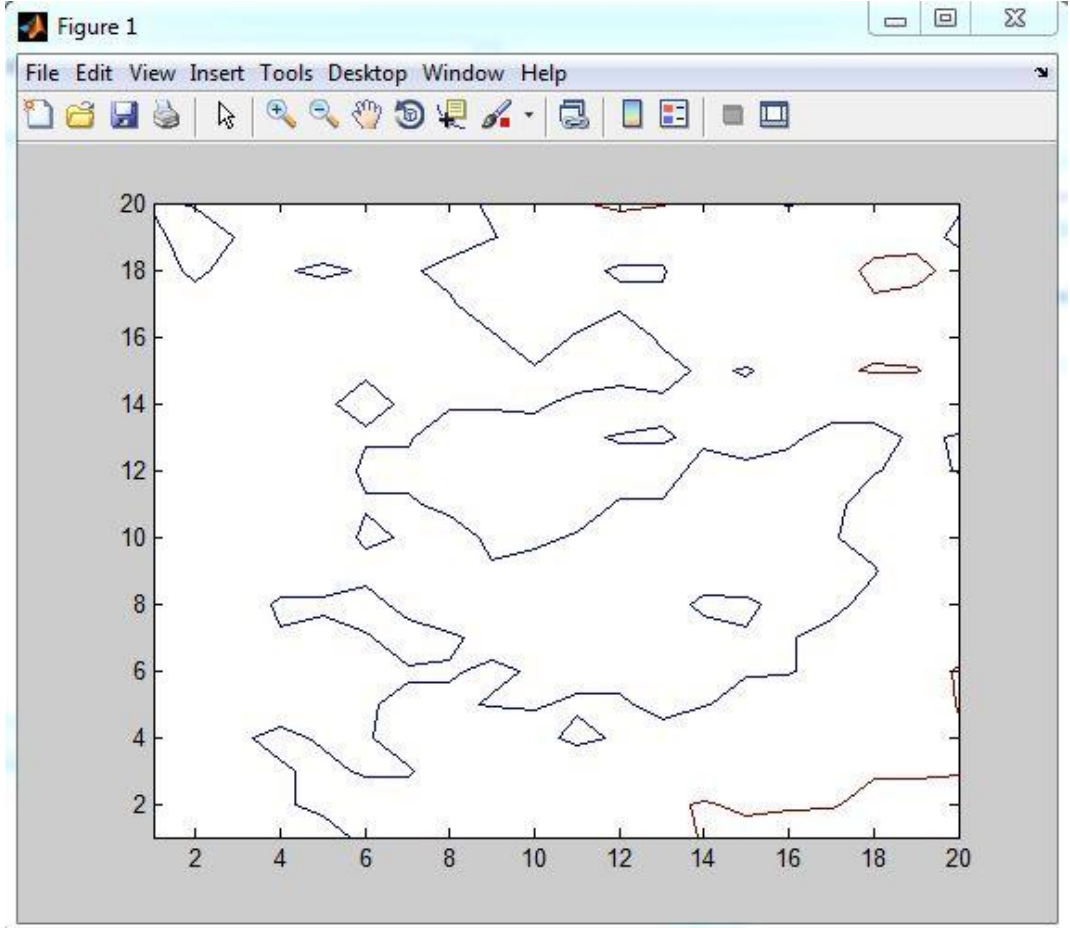
	1	2	3	4	5	6	7	8	9	10
1	54.5000	59.5000	61.5000	63.5000	65.0000	68.0000	70.5000	73.0000	76.0000	78.5000
2	54.0000	60.0000	60.5000	63.5000	66.5000	64.0000	65.0000	67.0000	69.5000	69.0000
3	53.5000	56.5000	58.5000	61.0000	60.5000	60.0000	57.5000	62.5000	65.5000	69.0000
4	54.0000	59.0000	61.0000	59.5000	56.5000	55.5000	58.5000	60.0000	63.0000	66.0000
5	53.0000	52.5000	57.5000	58.5000	60.5000	57.0000	57.5000	55.5000	61	66
6	52.5000	54.5000	59.0000	62.0000	62.0000	62.5000	60.0000	56.5000	60.5000	65
7	55	57.5000	59.5000	61	61.5000	62.5000	61.5000	62.5000	61.0000	63.0000
8	54.0000	57.5000	57.0000	59.5000	61	57.5000	62.0000	64.5000	69.5000	65.5000
9	58.0000	57.5000	59.5000	60.5000	67.5000	62.0000	63.0000	66.5000	69.5000	68
10	61.5000	57.0000	57.0000	57.0000	63.5000	68	68.0000	63.5000	65.5000	62.5000

Oluşturulan matrisler $cA / 256$ yapılarak normalize edilir ve aşağıdaki gibi matrisler oluşturulmuş olur.

	1	2	3	4	5	6	7	8	9	10
1	0.2129	0.2324	0.2402	0.2480	0.2539	0.2656	0.2754	0.2852	0.2969	0.3066
2	0.2109	0.2344	0.2363	0.2480	0.2598	0.2500	0.2539	0.2617	0.2715	0.2695
3	0.2090	0.2207	0.2285	0.2383	0.2363	0.2344	0.2246	0.2441	0.2559	0.2695
4	0.2109	0.2305	0.2383	0.2324	0.2207	0.2168	0.2285	0.2344	0.2461	0.2578
5	0.2070	0.2051	0.2246	0.2285	0.2363	0.2227	0.2246	0.2168	0.2383	0.2578
6	0.2051	0.2129	0.2305	0.2422	0.2422	0.2441	0.2344	0.2207	0.2363	0.2539
7	0.2148	0.2246	0.2324	0.2383	0.2402	0.2441	0.2402	0.2441	0.2383	0.2461
8	0.2109	0.2246	0.2227	0.2324	0.2383	0.2246	0.2422	0.2520	0.2715	0.2559
9	0.2266	0.2246	0.2324	0.2363	0.2637	0.2422	0.2461	0.2598	0.2715	0.2656
10	0.2402	0.2227	0.2227	0.2227	0.2480	0.2656	0.2656	0.2480	0.2559	0.2441

İşlenmiş hayvansal derilerin yüzey yapılarının belirlenmesi için grafik çizim yöntemlerinden biri olan Contour (eş yükselti eğrisi) kullanılmıştır Şekil 5.5'de gösterildiği gibi görüntü elde edilir. Contour aynı yükseltide olan noktaların birleştirilmesi ile elde edilen eş yükselti eğrileridir. Contour kullanılarak oluşturulan matrisler aşağıdaki gibidir.

0,1600	0,1567	0,1567	0,1500	0,1467	0,1483	0,1500	0,1533	0,1500	0,1467	0,1422	0,1433
0,1400	0,1333	0,1400	0,1467	0,1500	0,1600	0,1700	0,1800	0,1900	0,1967	0,2000	0,5867
0,0678	0,0700	0,0733	0,5867	0,1133	0,1200	0,1267	0,5867	0,1267	0,1300	0,1400	0,1417
0,1417	0,1400	0,1300	0,1233	0,1233	0,1200	0,1100	0,1083	0,1067	0,1000	0,0967	0,0900
0,0833	0,0800	0,0733	0,0800	0,0900	0,1000	0,1100	0,1133	0,1100	0,1000	0,0900	0,0800
0,0733	0,0700	0,0667	0,0600	0,0500	0,0433	0,0467	0,0500	0,0600	0,0633	0,0633	0,0633
0,0600	0,0500	0,0467	0,0400	0,0333	0,0367	0,0400	0,0433	0,0500	0,0567	0,0500	0,0467
0,0500	0,0600	0,0667	0,0667	0,0700	0,0800	0,0867	0,0800	0,0711	0,0717	0,0733	0,0733
0,0800	0,0867	0,0900	0,0967	0,1000	0,1017	0,1033	0,1067	0,1100	0,1200	0,1233	0,1300
0,1400	0,1411	0,1417	0,1400	0,1333	0,5867	0,1483	0,1500	0,1533	0,5867	0,1667	0,1700
0,1767	0,1800	0,1833	0,1833	0,5867	0,2000	0,1967	0,2000	0,5867	0,1200	0,1133	0,1200




Şekil 5. 5: Contour Kullanılarak Elde Edilen Görüntü

İşlenmiş hayvansal derilerin renk tonları için normalize edilmiş matrisler ve yüzey yapıları için oluşturulan matrisler YSA'nın girişi olarak kullanılmaktadır.


5.3. YSA'nın Eğitilmesi

Elde edilen işlenmiş hayvansal deri görüntülerinin 37 tanesini YSA'nın eğitilmesi için 18 tanesinide test için kullanıldı. Eğitim için hazırlanmış 37 verinin 25 tanesi siyah renkte 12 tanesi ise kahverenktedir. 25 siyah işlenmiş hayvansal deri görüntüsünün değerleri için bir eğitim dosyası oluşturuldu. 10 siyah işlenmiş hayvansal deri görüntüsünün değerleri içinde test dosyası oluşturuldu. 12 kahverengi işlenmiş hayvansal deri görüntüsünün değerleri için bir eğitim dosyası oluşturuldu. 8 kahverengi işlenmiş hayvansal deri görüntüsünün değerleri içinde test dosyası oluşturuldu. Bu oluşturulan veriler işlenmiş hayvansal derilerin renk tonları için siyah ve kahverengi için ayrı ayrı çıkış dosyası oluşturuldu. Ayrıca işlenmiş hayvansal derilerin yüzey yapılarının belirlenmesi için elimizdeki siyah ve kahverenkteki görüntülerin ayrı ayrı eğitim ve test dosyaları oluşturuldu. Siyah renk için 25 tanesini YSA'nın eğitilmesi için 10 tanesinide YSA'nın test edilmesi için hazırlandı. Kahverengi için 12 tanesini YSA'nın eğitilmesi için 8 tanesinide YSA'nın test edilmesi için hazırlandı. Bu oluşturulan veriler işlenmiş hayvansal derilerin yüzey yapıları için siyah ve kahverengi çıkış dosyası oluşturuldu.



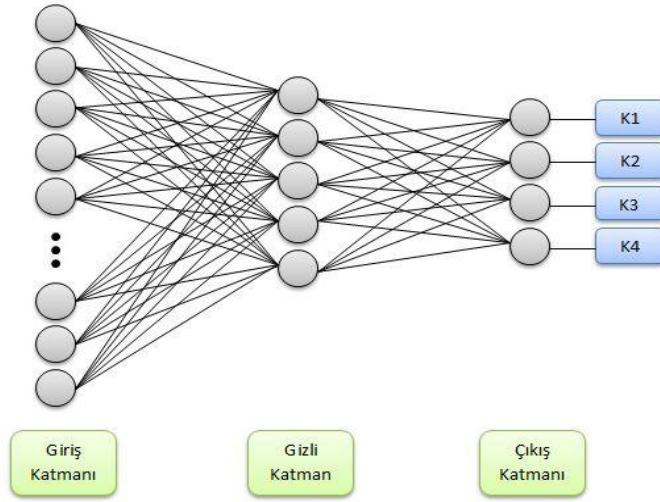
Şekil 5. 6: MLP Mimarisi Siyah Renk

Şekil 5.6'da Siyah renk için hazırlanmış MLP mimarisini bulunmaktadır.




Şekil 5. 7: MLP Mimarisi Siyah Yüzey

Şekil 5.7’de Siyah yüzey için hazırlanmış MLP mimarisini bulunmaktadır.



Şekil 5. 8: MLP Mimarisi Kahve Renk

Şekil 5.8’de Kahve renk için hazırlanmış MLP mimarisini bulunmaktadır.




Şekil 5. 9: MLP Mimarisi Kahve Yüzey

Şekil 5.9’da Kahve yüzey için hazırlanmış MLP mimarisini bulunmaktadır.

İşlenmiş hayvansal derilerin renk tonlarında siyah renk için 100 girişli veri oluşturuldu. Yüzey yapısı için ise 290 girişli veri oluşturuldu. Dalgacık sabitleri ağa giriş olarak verildi. Çıkış olarak ise belirlemiş olduğumuz renk tonları ve yüzeyler için deri grupları verildi.


İşlenmiş hayvansal derilerin renk tonlarında kahve renk için 100 girişli veri oluşturuldu. Yüzey yapısı için ise 161 girişli veri oluşturuldu. Dalgacık sabitleri ağa giriş olarak verildi. Çıkış olarak ise belirlemiş olduğumuz renk tonları ve yüzeyler için deri grupları verildi.

YSA programın Geri Besleme algoritmasına göre çalışmaktadır²⁹. Programın ilk görüntüsü Şekil 5.10 ve Şekil 5.11’de gösterilmiştir.



Şekil 5. 10: Kullanılan Program Renk Belirleme

²⁹ SIRVAN Osman, KARLIK Bekir, TUNALI Turhan, "Biometric Recognition Purposes of Security Using Artificial Neural Networks", HITEK'2004, Dec. 2004, 2, pp. 591-594



Şekil 5. 11: Kullanılan Program Yüzey Belirleme

Programımızı çalıştırdıktan sonra dosya seç butonuna basılarak eğitim.txt dosyamızı yüklüyoruz. Programdaki istenilen yerler doldurulduktan sonra eğitime başlatılır. Ağın en düşük hata değeri verdiği öğrenme oranı ve momentum değeri ayarlanır. En düşük hata değeri bulunduğu eğitime tamamlanır. Öğrenme oranı ve momentuma göre elde edilen değerler Tablo 5.1’de verildiği gibidir. Eğitim değerleri Tablo 5.2’de verildiği gibidir.


10000 İterasyon	MOMENTUM								
ÖĞRENME	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
0,1	0,0548	0,0529	0,0538	0,0532	0,0558	0,0546	0,0531	0,0514	0,0508
0,2	0,4816	0,4988	0,4834	0,4979	0,4990	0,4988	0,4975	0,4962	0,4812
0,3	0,4950	0,4950	0,4944	0,4946	0,4945	0,4943	0,4946	0,4945	0,4941
0,4	0,4939	0,4936	0,4952	0,4938	0,4973	0,4938	0,4939	0,4952	0,4961
0,5	0,9707	0,9726	0,9627	0,9724	0,9737	0,9736	0,9618	0,9686	0,9474
0,6	0,9746	0,9746	0,9752	0,9740	0,9283	0,9742	0,9741	0,9739	0,9748
0,7	0,9758	0,9752	0,9747	0,9757	0,9756	0,9753	0,9760	0,9754	0,9746
0,8	0,9750	0,9749	0,9755	0,9752	0,9748	0,9759	0,9757	0,9758	0,9756
0,9	0,9751	0,9758	0,9802	0,9754	0,9754	0,9755	0,9757	0,9752	0,9755

Tablo 5. 1: En iyi Momentum ve Öğrenme Oranının Belirlenmesi


	İTERASYON SAYISI									
LEARNING RATE	1000	2000	3000	4000	5000	6000	7000	8000	9000	10000
0,1	5,6733	3,8745	2,1939	1,3002	0,4446	0,2237	0,1368	0,0938	0,0698	0,0551
0,2	5,0254	2,1597	1,2438	0,6384	0,5449	0,5207	0,5101	0,5042	0,5005	0,4979
0,3	4,1196	1,7621	1,0796	0,9906	0,5572	0,5076	0,5005	0,4974	0,4956	0,4945
0,4	3,6383	1,6762	1,4330	0,9897	0,9782	0,9620	0,5056	0,4970	0,4950	0,4940
0,5	3,4015	1,6216	1,4578	0,9884	0,9778	0,9756	0,9743	0,9726	0,9590	0,5014
0,6	3,3897	1,5742	1,4606	1,4561	1,4534	1,0210	0,9769	0,9756	0,9749	0,9742
0,7	3,1174	1,5833	1,4601	1,4572	1,4563	1,4557	1,4551	1,4540	1,0439	0,9765
0,8	3,3621	1,9999	1,4590	1,4555	0,9815	0,9768	0,9761	0,9757	0,9754	0,9751
0,9	3,1289	2,0577	1,4588	1,4572	1,4565	1,4555	1,1777	0,9773	0,9767	0,9764

Tablo 5. 2: Eğitim Değerleri


En iyi Momentum ve öğrenme oranı seçildikten sonra 10000 iterasyon yapılarak hata değeri 0,055120891 olarak bulunur Tablo 5.2’de görüldüğü gibi. Şekil 5.12’de her iterasyondaki hata değişimi gösterilmiştir. Şekil 5.13’de 10000 iterasyondaki öğrenme oranına göre değişimi gösterilmiştir.



Şekil 5. 12: Hatanın İterasyona Göre Değişim Grafiği




Şekil 5. 13: İterasyonun Hataya Göre Değişim Grafiği




Şekil 5. 14: Siyah Renk Verilerinin Eğitilmiş Hali

5.4. Test Edilmesi


Elde edilen siyah renk verileri Şekil 5.14'deki gibi eğitildikten sonra eğitilmiş verilerin Şekil 5.15'teki gibi testi gerçekleştirilir. Test edilecek eğitilmemiş veri dosyaları yüklenerek Şekil 5.16 ve 5.17'deki gibi doğrulama gerçekleştirilir. Verilerdeki her bir satır ayrı bir işlenmiş hayvansal deriye ait yüzey verisidir. Eğitilmiş giriş verileri ve eğitilmemiş giriş verileri programda kontrol edilerek sonuçlar değerlendirilir ve işlenmiş hayvansal deriler arasında sınıflandırma yapılarak işlem tamamlanmış olur.



Şekil 5. 15: Eğitilmiş Siyah Renk Veri Setinin Test Sonucu




Şekil 5. 16: Eğitilmemiş Siyah Renk Veri Setinin Test Sonucu




Şekil 5. 17: Eğitilmemiş Siyah Renk Veri Setinin Test Sonucu – 2


Diğer elde edilen siyah yüzey verileri Şekil 5.18'deki gibi eğitilerek testi gerçekleştirilir. Test edilecek eğitilmemiş veri dosyaları yüklenerek Şekil 5.19 ve Şekil 5.20'deki gibi doğrulama gerçekleştirilir.



Şekil 5. 18: Siyah Yüzey Veri Setinin Eğitilmiş Hali




Şekil 5. 19: Eğitilmemiş Siyah Yüzey Veri Setinin Test Sonucu




Şekil 5. 20: Eğitilmemiş Siyah Yüzey Veri Setinin Test Sonucu – 2


Diğer elde edilen kahve renk verileri Şekil 5.21'deki gibi eğitildikten sonra eğitilmiş verilerin Şekil 5.22'deki gibi testi gerçekleştirilir. Test edilecek eğitilmemiş veri dosyaları yüklenerek Şekil 5.23 ve 5.24'deki gibi doğrulama gerçekleştirilir.




Şekil 5. 21: Kahve Renk Verilerinin Eğitilmiş Hali



Şekil 5. 22: Eğitilmiş Kahve Renk Veri Setinin Test Sonucu




Şekil 5. 23: Eğitilmemiş Kahve Renk Veri Setinin Test Sonucu




Şekil 5. 24: Eğitilmemiş Kahve Renk Veri Setinin Test Sonucu – 2


Diğer elde edilen kahve yüzey verileri Şekil 5.25'deki gibi eğitildikten sonra eğitilmiş verilerin Şekil 5.26'daki gibi testi gerçekleştirilir. Test edilecek eğitilmemiş veri dosyaları yüklenerek Şekil 5.27 ve 5.28'deki gibi doğrulama gerçekleştirilir.




Şekil 5. 25: Kahve Yüzey Veri Setinin Eğitilmiş Hali



Şekil 5. 26: Eğitilmiş Kahve Renk Veri Setinin Test Sonucu




Şekil 5. 27: Eğitilmemiş Kahve Yüzey Veri Setinin Test Sonucu




Şekil 5. 28: Eğitilmemiş Kahve Yüzey Veri Setinin Test Sonucu – 2

Elde edilen veriler ile yapılan iterasyon sayısı araştırmasında 30.000 iterasyon seviyesinde ivmenin giderek yavaşladığı görülmektedir. Tablo 5.3 ve 5.4 de görüldüğü üzere hata oranı 0,01 seviyelerine inmektedir.



Tablo 5. 3: 3000'er iterasyonlu grafik



Tablo 5. 4: 5000'er iterasyonlu grafik

6.SONUÇ

Bu çalışmadaki amaç işlenmiş hayvansal derilerin renk tonlarına ve yüzey yapılarına göre sınıflandırılma işleminin bilgisayarlı ortamda hatanın minimize edilerek sınıflandırmanın sağlanmasıdır. Günümüzde işlenmiş hayvansal derilerin sınıflandırılması insan gözü ve bilgisiyle yapılmaktadır dolayısıyla hata olasılığı daha fazla bulunmaktadır.

Bu çalışmanın sonunda işlenmiş hayvansal derilerin renk tonlarının ve yüzey yapılarının tanımlanması sağlanmış bulunmaktadır. Ancak daha fazla materyalle ve daha kapsamlı bir çalışma ile çok daha iyi sonuçlara ulaşılabilir.

Bu çalışmanın en zor yanı işlenmiş hayvansal derilerin tekstil gibi standart yapıda (dokuda) olmayıp canlı bir yapıda olmasından dolayı yüzey yapısının incelenmesi kısmında yaşanmıştır. Renk tonlarında aynı rengin tonajlarının birbirlerine çok yakın olmasından dolayı değerlerin karışma ihtimali bulunmaktadır.

Bu çalışmada kullanılan $I = \text{rgb2gray}(\text{RGB})$ gerçek renkli RGB görüntüsünü gri yoğunluklu görüntüye dönüştürülür. Bu dönüştürme işlemi sırasında parlaklık korunurken ton ve dolgunluk bilgileri ortadan kaldırılır. RGB değerleri için gri tonlama değerleri ağırlık toplamını oluşturan R,G,B bileşenlerinin değerleri aşağıdaki gibidir.

$$0,2989 * R + 0,5870 * G + 0,1140 * B$$

Elde edilen görüntüler küçültülerek işlemler yapıldığı için daha net sonuçların elde edilebilmesi daha büyük görüntülerle çalışma yapılarak sağlanılabilir. Ancak görüntülerin büyümesi işlemlerin süresini uzatacağı için dezavantaj oluşturabilir. Küçültme işlemi için matlab programının resize işlemi kullanılmıştır. Kullanılan resize özelliği bikübik interpolasyondur. Bikübik interpolasyon özelliği çıkış piksel

değerine en yakın 4-4 komşuluk piksellerinin ağırlık ortalamasına göre çalışmaktadır. Resize ile istenilen boyuta kolayca dönüştürme yapılabilir. DWT’de ise alçak geçirgen ve yüksek geçirgen olmak üzere iki ye ayırarak işlemler gerçekleştirilir. Elde edilen değerler rastgele değerlerdir. Ayrıca görüntünün istenilen değere düşürülürken işlem süreci uzamaktadır. Bu sebeplerden dolayı görüntü öncelikle resize yöntemi ile küçültülür daha sonra dwt ile öz nitelik vektörü elde edilir. Oluşturulan veriler normalize edilerek programa aktarılır.

Yapılan araştırma sonucu iterasyon sayısının arttırılması ile hata oranının düşürülebileceği gözlemlenmiştir. Ancak belli bir seviyeden sonra iterasyon sayısının arttırılması zaman kaybına yol açacaktır. Hata oranındaki ivmenin yavaşlamaya başladığı yerde iterasyonun durdurulması zaman kaybının önüne geçilmesini sağlayacaktır. Bu çalışmada yapılan iterasyon araştırmasında 30.000 iterasyon seviyelerinde hata oranındaki ivme yavaşladığı için iterasyon sayımızı 30.000 de durdurabiliriz.

7. KAYNAKLAR

Alasdair McAndrew ,An Introduction to Digital Image Processing with Matlab Notes for SCM2511 Image Processing 1, Page 31-32,Semester 1, 2004

Becerikli Y. , Ders Notları, 2007

Culloch MC. , W.S., Pitts, W.H. 1943. *A logical calculus of the ideas immanent in neural nets*. Bull. Math.Biophys. 5:115-133.

Grossberg, S. 1986. *The Adaptive Brain I:Cognition, Learning, Reinforcement, and Rhythm, and The Adaptive Brain II:Visions, Speech, Language, and Motor Control*, Elsevier/North-Holland, Amsterdam.

Gutierrez,W. J., Grandin, R.D. 1989. Estimating hidden units for two layer perceptrons. Proc. of the 1st Int.Conf. on Artificial Neural Networks, London, U.K., October, 120-124.

Hebb, D.O. 1949. *The Organization of Behaviour*, John WileySons, New York.

Hopfield, J.J 1987. Learning algorithms and probability distributions in feedforward and feed-back networks. Proc.Nat.Acad.Sci 88:8429-8433.

Hopfield, J.J. 1982. *Neural networks and physical systems with emergent collective computational abilities*. Proc.Nat.Acad.Sci 79:2554-2558.

J.W.Kwon, Y.Y. Choo, H.H. Choi, J.M. Cho,G.S.Kil, *Development of Leather Quality Discrimination System by texture Analysis*. Dept. of Computer Eng., T.I.T., Pusan, South Korea

Karlık B., 1994, *Myoelectric Control of Multifunction Prosthesis Using Neural Networks*”, Yildiz Technical University, PhD, Thesis, Istanbul, Turkey

Karlık B., Ders Notları,2009-2010

Kohonen, T. 1984. *Self-Organization and Associative Memory*, Springer-Verlag, Berlin.

Kwak, C., Ventura, J. A. and Tofang-Sazi, K. (2000) A neural network approach for defect identification and classification on leather fabric. Department of Industrial and Manufacturing Engineering. The Pennsylvania State University, University Park, PA.

Minsky, M. ve Papert, S. 1969. *Perceptrons: An introduction to Computational Geometry*, MIT Press, Cambridge, MA.

MEGEP (Meslekî Eğitim Ve Öğretim Sisteminin Güçlendirilmesi Projesi). (2007), *Derinin Yapısı*, Giyim Üretim Teknolojisi, T.C. Milli Eğitim Bakanlığı, Ankara.

Pao, Y.H. 1989. *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley Publishing Co., Reading, Mass. patients with headache, *Headache.*, 41(8), 792-797, 2001.

Papakçı Selver, Kıvırcık ve Dalgıç Irkı Kuzu Derilerindeki Kolagen Miktarının Tayini ve Bunun Mamul Deri Üzerine Etkisi, Dericilik Araştırma Enstitüsü, İstanbul.

R. Gonzalez and R. Woods. *Digital Image Processing*. Addison-Wesley Press, 1993.

Rosenblatt, F. 1959. *Principles of Neuradynamics*, Spartan Books, New York.

Rosenblatt, F. 1962. *Principles of Neuradynamics: Perceptrons and The Theory of Brain Mechanisms*, Spartan Books, Washington D.C.

Rumelhart, D.E., Hinton, G.E., Williams, R.J. 1986. "Learning Internal Representations by Error Propagation", MIT Press, Cambridge, MA.

Rumelhart, D.E., McClelland, J.L., PDP Research Group 1986.

Rumelhart, D.E., McClelland, J.L., PDP Research Group 1986. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, v. 1: Foundations, MIT Press, Cambridge, MA.

Sirvan Osman, Karlık Bekir, Tunalı Turhan, "Biometric Recognition Purposes of Security Using Artificial Neural Networks", HITEK'2004, Dec. 2004, 2, pp. 591-594

Yagmur D. F.(2008). “*Automatic Recognition Of Retinopathy Diseases By Using Neural Network*”, Halic University, M.S. , Thesis, Istanbul, Turkey

Widrow, B., Hoff, M. 1960. *Adaptive switching circuits*. IRE WESCON Convention Record 4:96-104.

İnternet:

Elektronik Makale ve Yayınlar

Derinin kimyasal yapısı: <http://tr.wikipedia.org/wiki/Dericilik> (Erişim Tarihi: 14.02.2011)

8. ÖZGEÇMİŞ

Ad Soyad : İlyas AYDOĞAN

Doğum Tarihi : 02.04.1984

Doğum Yeri : Eminönü / İstanbul / Türkiye

Lise : Özel Fatih Anadolu Lisesi

Üniversite / Lisans : Haliç Üniversitesi Bilgisayar Mühendisliği