

**DİSMORFİK HASTALIKLARIN GÖRÜNTÜ ANALİZİ İLE
AYIRT EDİLMESİ**

**RECOGNITION OF DYSMORPHIC SYNDROMES USING
IMAGE ANALYSIS**

MEHMET EMRE SİPAHİ

Başkent Üniversitesi
Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin
Biyomedikal Mühendisliği Anabilim Dalı İçin Öngördüğü
YÜKSEK LİSANS TEZİ
olarak hazırlanmıştır.

Haziran 2008

Ankara

TEŐEKKÜR

Çalıőmalarım sırasında bilgisini, imkânlarını, hoőgörüsünü ve desteęini esirgemeyen danıőmanım Sayın Doç. Dr. Osman EROĐUL'a saygıyla teőekkürü bir borç bilirim.

Bana bilgisiyle arkadaőlığıyla destek olan Uęur CUNEDİOĐLU'na, Onur KOÇAK'a ve Evren ERKUT'a teőekkür ederim.

Var oluőumdan bu yana her őeyime katlanarak üzerlerine düşen bütün görevleri eksiksiz yerine getiren, őu an bulunduęum yerde olmamda büyük emek sahibi sevgili anneme, babama ve kardeőime çok teőekkür ederim. Ayrıca her zaman yanımda olan ve bana inanan Özge ÇELİK'e teőekkür ederim.

ÖZ

DİSMORFİK HASTALIKLARIN GÖRÜNTÜ ANALİZİ İLE AYIRT EDİLMESİ

Mehmet Emre SİPAHİ

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Dismorfiğin kelime anlamı insanın doğuştan şekil bozukluğu olarak tanımlanmaktadır. Dismorfik otozomal kromozom hastalıkların günümüzde en sık rastlanan sendromu trizomi 21 yani down sendromudur. Bu nedenle down sendromunun klinik ön tanı tespiti önem arz etmektedir. Klinik ön tanı, referans kitaplardaki örnek resimlerden karşılaştırma yolu ile veya hekimden hekime değişiklik gösteren tecrübe faktörü sayesinde konulabilmektedir. Bu çalışmada, down sendromu şüphesine sahip kişilere farklı klinik ön tanıların konulmasını engelleyebilmek ve bu işlemi hekimlerin tecrübelerinden bağımsız bir hale getirebilmek için karşılaştırma yönteminin niteliksel olarak incelenip görüntü analizi ile klinik ön tanının konulabilmesi hedeflenmiştir. Çalışmada 5-6 yaş grubundaki 18 adet down sendromlu çocuğun yüz fotoğrafları ile 18 adet normal morfolojiye sahip çocuğun yüz fotoğraflarından bir veri tabanı oluşturulmuştur. Fotoğrafların tamamında elastik yüz demet grafik yöntemi ile yüzdeki kritik noktalar tespit edilmiştir. Daha sonra bu kritik noktalardan klinik ön tanı için 10'ar adet öz nitelik vektörü elde edilmiştir. Öz nitelik vektörleri, oluşturulan MATLAB tabanlı bilgisayar programının eğitilmesinde kullanılmıştır. Bu eğitim işlemi yapay sinir ağları ile gerçekleştirilmiştir. Sonuç olarak, kullanılan iki farklı yapay sinir ağı metodu ile %68,7 doğrulukta down sendromlu kişinin klinik ön tanısı konulabilmektedir. İlerleyen çalışmalarda daha geniş veri tabanları oluşturularak başarı oranının artırılması mümkün olacaktır. Bu sayede dismorfik hastalıkların klinik ön tanısının konulmasında standardizasyona ulaşılması hedefi sağlanabilecektir.

ANAHTAR SÖZCÜKLER: Dismorfik Hastalıklar, Down Sendromu, Yüz Tanıma, Yapay Sinir Ağları,.

Danışman: Doç. Dr. Osman EROĞUL, Başkent Üniversitesi, Biyomedikal Mühendisliği Bölümü.

ABSTRACT

RECOGNITION OF DYSMORPHIC SYNDROMES USING IMAGE ANALYSIS

Mehmet Emre SIPAHI

Baskent University Institute of Science

Department of Biomedical Engineering

The lexical meaning of the dysmorphic is defined as the congenital malformation of human. At the present time, the most common syndrome of the dysmorphic autosomal chromosome diseases is Trisomy 21, in other words down syndrome. Therefore, clinic pre-diagnosis of down syndrome carries severity. Clinic pre-diagnosis can be estimated by either comparison of the images on reference books or experience which can show difference from one clinician to other. On this study, in order to obstruct the dissimilarity of prediagnosis for the patients who are doubted likely down syndrome and to render this process clinician independent, it is aimed to determine the clinic prediagnosis by the image analysis subsequently qualitatively observation of the comparison method. Regarding our study, a database has been constituted with the face photos of 18 children who has already been diagnosed down syndrome and 18 children who has normal morphology. At the MATLAB based program which is written for our thesis, the fiducial points on faces are determined by using the elastic face bunch graph method for all photos. Afterwards, 10 feature vectors for all faces are obtained from these fiducial points for clinic prediagnosis. Feature vectors are used for training the program by artificial neural networks. In conclusion, by using two different artificial neural network method, the determination of clinic prediagnosis for a patient who has down syndrome can be done with an accuracy of 68%. For further studies, it will be possible to increase the success ratio by creating larger databases. As a result of these studies, we will be able to reach a standardization for pre-diagnosis of dysmorphic diseases.

KEYWORDS: Dysmorphic Diseases, Down Syndrome, Face Recognition, Artificial Neural Networks.

Advisor: Doc. Dr. Osman EROĞUL, Baskent University, Department of Biomedical Engineering.

İÇİNDEKİLER LİSTESİ

	Sayfa
TEŞEKKÜR	i
ÖZ	ii
ABSTRACT	iii
İÇİNDEKİLER LİSTESİ.....	iv
ŞEKİLLER LİSTESİ	vii
TABLolar LİSTESİ	viii
SİMGELER VE KISALTMALAR LİSTESİ	ix
1. GİRİŞ.....	1
1.1 Kapsam	1
1.2 Amaç	1
1.3 Yöntem	2
2. TEMEL BİLGİLER	3
2.1 Dismorfik Hastalıklar	3
2.1.1. Trizomi 18 sendromu (Edwards sendromu)	4
2.1.2 Trizomi 13 sendromu (Patau Sendromu)	5
2.1.3 Trizomi 8 sendromu (Trizomi C).....	5
2.1.4 Trizomi 22 sendromu	5
2.1.5 Trizomi 21 sendromu (Down sendromu)	6
2.1.5.1 Down sendromunun oluşumu	7
2.1.5.2 Down sendromunun teşhisi.....	10
2.2. Yüz Tanıma	11
2.2.1 Temel Bileşen Analizi (TBA).....	11
2.2.2 Elastik Yüz Demet Grafiği (EYDG).....	12
2.2.2.1 Gabor dalgacıkları ve jetler	13
2.2.2.2 Jetlerin karşılaştırılması	15
2.2.2.3 Yerinden çıkarma tahmini	16
2.2.2.4 Elastik demet grafik eşleştirmeye yüz temsilleri oluşturmak.....	19

2.2.2.5 Grafiklerin elle tanımı	19
2.2.2.6 Eşleştirme prosedürü	20
2.3 Yapay Sinir Ağları (YSA)	21
2.3.1 YSA'nın tarihçesi.....	22
2.3.2 Yapay sinir ağı hücresi.....	26
2.3.3 Aktivasyon fonksiyonları.....	30
2.3.4 YSA modelleri	32
2.3.5 YSA'nın eğitilmesi	34
2.3.6 YSA'nda öğrenme algoritmaları	34
2.3.6.1 Geri yayılım öğrenme algoritması	35
2.3.7 Matlab'da yapay sinir ağları fonksiyonları.....	39
2.3.7.1 Logsig fonksiyonu	39
2.3.7.2 Tansig fonksiyonu	40
2.3.7.3 Purelin fonksiyonu.....	40
2.3.8 Bir Ağ Oluşturmak (newff).....	41
2.3.9 Ağın Eğitimi	41
2.3.10 Geri yayılım algoritması	42
2.3.11 Takım eğitimi (train)	42
2.3.12 Takım gradyant azalışı (traingd).....	42
2.3.13 Momentumlu takım gradyant azalışı (traingdm)	44
2.3.13.1 Değişken Öğrenim Katsayısı (traingda, traingdx)	45
3. YÖNTEMLER	47
3.1 Fotoğraf Veri Tabanının Oluşturulması	47
3.2. Gabor Dalgacıkların Oluşumu	47
3.2 Yüz Üzerinde Nokta Tespiti	49
3.2.1 EDGM ve IMEM Metotları	50
3.2.2 Noktacık küme optimizasyonu (NKO)	53

3.2.3 İşaretleyici bulma	55
3.3 YSA Uygulaması	56
3.3.1 Öznitelik vektörlerinin oluşturulması	56
3.3.2 Gradyant azaltmalı geri yayılım yöntemi ile eğitim	58
3.3.2.1 Traingdx.....	58
3.3.3 Test yöntemleri.....	60
4.SONUÇLAR.....	62
4.1 Fotoğraf Veri Tabanı	62
4.2 YDG İle Noktacık Tespit Sonuçları	64
4.3 YSA'da Ayrı Veri Deneme Yöntemi Sonuçları	65
5. TARTIŞMALAR	71
5.1 Çalışmadaki Sınırlayıcı Etkenler.....	72
5.2 Gelecekteki Çalışmalar	73
KAYNAKLAR LİSTESİ.....	74

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1 Üç adet 21. kromozom gösterimi	7
Şekil 2.2 Monozominin yapısı.....	8
Şekil 2.3 Bir yüzün grafik temsili.....	14
Şekil 2.4 Yüz Demet Grafiği (YDG)	18
Şekil 2.5 Farklı pozlar için nesne uyarlamalı ızgaralar	20
Şekil 2.6 Basit sinir hücresi.....	27
Şekil 2.7 Sinir sisteminde bilgi akışı	28
Şekil 2.8 Basit yapay sinir ağı modeli	29
Şekil 2.9 Eşik aktivasyon fonksiyonu	30
Şekil 2.10 Doğrusal aktivasyon fonksiyonu	31
Şekil 2.11 Logaritma Sigmoid aktivasyon fonksiyonu	31
Şekil 2.12 İleri beslemeli yapı	32
Şekil 2.13 Geri beslemeli yapı	33
Şekil 2.14 İleri beslemeli çok katmanlı sinir ağı	36
Şekil 2.15 X girişli bir nöronun temel grafik gösterimi	39
Şekil 2.16 Tan-sigmoid transfer fonksiyonu.....	40
Şekil 3.1 5 frekans 8 farklı yönelimli gabor dalgacıkları	48
Şekil 3.2 Jet akış şeması.....	49
Şekil 3.3 a) Yüzü bulmak için ızgaralar b) Yüzü tanımak için ızgaralar	52
Şekil 3.4 Elastik demet grafik örneği	53
Şekil 3.5 NKO akış diyagramı.....	54
Şekil 3.6 Maskedeki seçilen noktaların gösterimi	57
Şekil 3.7 Yöntem akış şeması	61
Şekil 4.1 a) ve b) Fotoğraf veri tabanından örnek fotoğraflar.....	63
Şekil 4.2 a), b), c) ve d) YSA ile noktacık tespit sonuçları	65

TABLULAR LİSTESİ

Sayfa

Tablo 4.1 Ayrı Veri Deneme Yöntemi Sonuçları-1	66
Tablo 4.2 Ayrı Veri Deneme Yöntemi Sonuçları-2	67
Tablo 4.3 Ayrı Veri Deneme Yöntemi Sonuçları-3	68
Tablo 4.4 Bir Veri Dışarı Yöntemi Sonuçları-1	69
Tablo 4.5 Bir Veri Dışarı Yöntemi Sonuçları-2	70
Tablo 5.1 Genel İstatistiki Sonuçlar-1	71
Tablo 5.2 Genel İstatistiki Sonuçlar-2	71

SİMGELER VE KISALTMALAR

YDGM	Yüz Demet Grafik Metodu
YSA	Yapay Sinir Ağları
IQ	Intelligence Quotient – Zeka derecesi
TBA	Temel Bileşen Analizi
EYDG	Elastik Yüz Demet Grafiği
ART	Adaptif Rezonans Teorisi
RTF	Radyal Tabanlı Fonksiyonlar
PNN	Probabilistik Sinir Ağları
GRNN	Genel Regrasyon Sinir Ağları
NKO	Noktacık Küme Optimizasyon
EDGM	Elastik Demet Grafik Metodu
YDG	Yüz Demet Grafiği
$I(\vec{x})$	Gri Değerler
$\psi_j(\vec{x})$	Gabor Çekirdeği
\vec{k}_j	Dalga vektörü
S_ϕ	Taylor Uzantısı
W	Ağırlıklar Matrisi
f	Aktivasyon Fonksiyonu
$o(t)$	t anındaki çıkışı
Δ	Gecikme süresi
$e(k)$	Hata
E	Performans İndeksi
α	Öğrenme Oranı

x_K	Anlık ağırlık ve tahminler
g_K	Anlık Gradyant
IMEM	İşaretleyici Model Eşleştirme Metodu
IM	İşaretleyici Model
S_α	Benzerlik Fonksiyonu
V_i	Noktacığın pozisyon değişimi
P_i	Noktacığın bir önceki pozisyonu
g	Tekrarlama Sayısı
N	Noktacık Sayısı
c_1	İvme Sabiti
c_2	İvme Sabiti
w	Eylemsizlik Ağırlığı

1. GİRİŞ

1.1 Kapsam

Bilimsel bir disiplin olarak dismorfoloji, embriyoloji, klinik genetik ve pediatri alanlarından kavram, bilgi ve teknikleri bir araya getirir. Dismorfik otozomal kromozom hastalıkların başında günümüzde en sık rastlanan sendrom down sendromudur ve sendromun tanımlanması önem arz etmektedir.

Günümüzde down sendromunun kesin teşhisi laboratuvar ortamında kromozomların incelenerek genetik testlerin uygulanması ile mümkün olmaktadır. Genetik testler kesin sonuç vermesine rağmen pahalı sistemler gerektirir. Bu nedenle uzmanlar ilk aşamada, genetik testleri gerçekleştirmeden önce, fenotipteki değişimleri göz önünde bulundurarak hastalığın tanısını koymaktadırlar. Bunun için referans kitaplarda bulunan daha önce kesin tanısı konulmuş hastaların özellikleri ile karşılaştırma yöntemi kullanılarak hastalık tanısının konulması amaçlanmaktadır.

Karşılaştırma yöntemi uygulanırken uzman hekimin hastalık ile ilgili tecrübesi hastalığın tanısının konulmasında büyük rol oynamaktadır ve uzman hekimin deneyimi ile teşhis koyması sübjektif bir metottur. Bu nedenle günümüzde, sübjektif olmayan, hastalığın tespitini otomatik olarak gerçekleştirebilecek ve pahalı sistemlere gerek duymayan yöntemlerin gerçekleştirilmesine ihtiyaç duyulmaktadır.

1.2 Amaç

Tezin ana amacı Yüz Demet Grafik Metodu (YDGM) kullanılarak yüz fotoğrafları çekilen down sendromlu ve normal morfolojiye sahip çocukların fotoğraflarındaki kritik noktaların tespit edilmesi ve kritik noktalardan öznitelik vektörlerinin elde edilerek Yapay Sinir Ağları (YSA) yöntemi yardımıyla hastalığın klinik ön tanısı hakkında karar verebilmektir. Bu doğrultuda projeyi tamamlamak için gerçekleştirilecek bölümler maddeler halinde aşağıda sıralanmıştır;

- ✓ YDGM kullanarak yüzdeki kritik noktaların tespit edilmesi,
- ✓ Tespit edilen kritik noktalardan referans noktaların ayırt edilmesi ile öznitelik vektörlerinin belirlenmesi,
- ✓ Oluşturulan MATLAB tabanlı programın YSA ile eğitim işleminin gerçekleştirilmesi,
- ✓ YSA'nın test edilmesi ve sonuçların değerlendirilmesi.

1.3 Yöntem

Giriş bölümünde tez konusu ile ilgili ön bilgiler, tezde yapılması hedeflenen temel amaçlar hakkında bilgi verilmiştir. Tezin kalan kısmında, bu amaçlara ulaşmada etkili rol oynayan çalışmalara değinilecektir.

İkinci bölümde dismorfik hastalıklar ve down sendromu, yüz demet grafik metodu, yapay sinir ağlarının çalışma prensibi konularıyla ilgili literatür bilgileri “TEMEL BİLGİLER” başlığı altında sunulmaktadır.

Üçüncü bölümde yüz demet grafik metodu ile yüz üzerindeki noktaların tespiti, öznitelik vektörlerinin çıkartılması ve programın öznitelik vektörleri kullanılarak yapay sinir ağı yöntemi olan geri yayılım algoritması ile eğitilmesi ve diğer işlemler “YÖNTEMLER” ana başlığı altında anlatılmaktadır.

Dördüncü bölümde “SONUÇLAR” başlığı altında programdan elde edilen sonuçlar gösterilmekte ve bu sonuçların daha önce yapılan çalışmalar ile karşılaştırılması yer almaktadır.

Beşinci bölümde “TARTIŞMALAR” başlığı adı altında sınırlayıcı etkenler ve gelecekte yapılacak çalışmalar alt başlıklarına yer verilmektedir.

2. TEMEL BİLGİLER

2.1 Dismorfik Hastalıklar

“Dismorfik” kelimesinin anlamı ilk olarak 1960 yılında Dr. David Smith tarafından insanın doğuştan şekil bozukluğu olarak açıklanmıştır [1]. Dismorfik hastalıkların oluşumunu etkileyen birçok faktör bulunmaktadır. Bunların başında akraba evlilikleri, hamilelik esnasında bireyin bulunduğu çevre koşulları, beslenme şekilleri ve çeşitli çevresel faktörler genetik dizilimin oluşumunda etkili olmaktadır. Bu dizilim esnasında oluşabilecek hata bebeğin doğuştan şekil bozukluğuna ve/veya mental retardasyona uğramasına sebep olabilmektedir.

Yeni doğan bebeklerin %2–3’ünde çoğu genetik bozukluk sonucu oluşan doğuştan anomaliler saptanmaktadır. Yaşamın daha sonraki evrelerinde ortaya çıkan genetik hastalıklarda bu oran %7–8 değerine ulaşmaktadır. Doğuştan şekil bozukluluğunun nedenleri günümüzde halen araştırılmakta ve çözüm üretilmeye çalışılmaktadır.

Literatürde Dismorfik bozukluk olarak kabul edilen bir çok sendrom bulunmaktadır. Bunların başlıcaları; Trizomi 18 sendromu (Edwards Sendromu), Trizomi 13 sendromu (Patau Sendromu), Trizomi 8 sendromu (C sendromu), Trizomi 22 sendromu, Trizomi 21 Down sendromudur (Mongolizm). Aşağıdaki bölümlerde bu sendromlarla ilgili bilgiler aktarılmaktadır.

2.1.1. Trizomi 18 sendromu (Edwards sendromu)

Edwards sendromu olarak bilinen Trizomi 18 sendromu Down sendromundan sonra en sık görülen anomalidir. İnsan kromozom diziliminde 18 numaralı kromozomun düzensizlik sonucu 3 tane olması ile oluşur [2]. Görülme sıklığının yaklaşık 6000 gebelikte bir olduğu kabul edilmektedir.

Edwards sendromunda bebeklerin dış görünüşleri tipiktir. Bireyde oldukça ciddi bir gelişme geriliği söz konusudur. Baş kısmında gerilik daha da belirgindir ve bu durum literatürde mikrosefali olarak adlandırılmaktadır. Ayrıca alt çene oldukça ufak (mikrognati) görünmektedir. Kulaklarda ise gelişimsel problemler ve kulakların normalden daha aşağıda yerleşmiş olması da tipiktir. Bunların dışında bebeklerin çok büyük kısmında ciddi kalp problemleri görülebilmektedir. Aynı zamanda sindirim sistemi, böbrek ve genital sistemde de problemler sıklıkla görülebilmektedir. Erkek bebeklerde genelde inmemiş testis durumu gözlemlenmektedir [3]. Doğumsal kalp problemleri sebebi başta olmak üzere, bebeklerin çok büyük bölümü ilk sene içinde çeşitli nedenlerden dolayı hayatlarını kaybetmektedirler [4].

Yapısal bozuklukların düzeltilmesi yaşam süresini uzatabilmektedir. Ancak zekâ geriliği ve motor gelişimdeki (hareket yeteneği, kas kullanımı) ağır gerilik kalıcı olmaktadır. Gebelik sırasında ultrasonografi bulgularıyla Edwards sendromundan kuşkulanan genelde mümkündür [5]. Erken dönemde başlayan gelişme geriliği, özellikle yüzün yandan izlenmesiyle saptanabilecek mikrognati, amniotik sıvının fazlalığı, omfalosel (karın duvarındaki gelişim bozukluğuna bağlı olarak karın içi organlarının dışarıya çıkması) Edwards sendromunun endikasyonlarıdır.

Bebeklerde normal doğum eylemi sırasında kalp atışlarında bozulma sıkça görüldüğünden, tanı konmamış Edwards sendromlu bebeklerin acil sezaryen ile doğurtulması yoğun bir şekilde görülebilmektedir. Çoğu erken dönemde kaybedildiğinden bu durum anne için gereksiz bir risk oluşturmaktadır [6].

2.1.2 Trizomi 13 sendromu (Patau Sendromu)

Trizomi 13, sitogenetik olarak ilk defa Patau ve arkadaşları tarafından tanımlanmıştır [7]. Klinik fenotipi ise Smith tarafından tanımlanmıştır [8]. Trizomi 13 yaklaşık olarak 10.000 canlı doğumda bir görülmektedir [9]. Annenin yaşındaki artışla birlikte görülme sıklığı artmaktadır [10]. Trizomi 13 genel olarak düşükle

sonuçlanmaktadır. Düşük erken gebelikte olabileceği gibi 20. haftaya kadar gecikebilmektedir ya da erken doğum olabilmektedir [11].

Trizomi 13'lü doğan 200 canlı infantın izlendiği geniş serili bir çalışmada [12]; %28'inin yaşamın ilk haftasında, %44'ünün ilk ayında, %73'ünün ilk 4 ay içerisinde öldükleri bildirilmektedir [12]. Bu bebeklerde en belirgin anormaliler beyin ve yüz ile ilgili olanlardır. Holoprozonsefalide de beynin ön kısmı ve orta hat yüz yapılarının gelişimi bozulmaktadır. En ileri şekli olan siklopide, orta hatta yalnız bir tane göz bulunmaktadır. Trizomi 13'te diğer trizomilerde olduğu gibi kalp, sindirim sistemi ve diğer sistemlere ait anormallikler yüksek oranda bulunmaktadır [13]. Çok sık oranda abdominal anomaliler görülmektedir [14].

2.1.3 Trizomi 8 sendromu (Trizomi C)

Trizomi 8, Trizomi C olarakta bilinmektedir. Trizomi C sendromlu bireylerde doğuştan şekil bozukluğuna sahip kafa yapısı ve doğuştan kalp hastalığı görülmektedir. Bunun yanında eklem hareketlerinde kısıtlılık, el ayası ve ayak tabanlarında derin fleksiyon katlantıları oluşmaktadır. Trizomi C sendromunun endikasyonları mental retardasyon, vertebral anomaliler, boy kısalığı ve düşük kilo gibi bulgulardır. Diğer sendromlara göre daha yeni bir sendrom olarak görülmektedir ve ilgili klinik çalışmalar yoğun olarak devam etmektedir [15].

2.1.4 Trizomi 22 sendromu

Trizomi 22 sendromunun endikasyonları mikrosefali, düşük kulak, yarık damak, mikrognati, mental motor retardasyon, kardiyak ve renal anomaliler, iskelet anomalileri ve genital anomaliler olmakla birlikte oldukça nadir görülen bir sendromdur [16]. Mikrognati, yarık damak ve kalp hastalığı trizomi 22 sendromuna sahip bir çok kişide görülen en sık anomalilerdir [17]. Komplet formları genellikle düşük ile sonuçlanmaktadır ve canlı doğan bebekler ise çoğunlukla yaşamın ilk birkaç gününde kaybedilmektedir [18].

2.1.5 Trizomi 21 sendromu (Down sendromu)

Dismorfik hastalıkların en başında gelen Down sendromu, 1866 yılında klinik olarak J. Langdon Down tarafından otozomal anöploid sendromlarından biri olarak tanımlanmıştır. Hastalığın genetik bir hastalık ve kromozomal kaynaklı olduğu 1959 yılında Lejeune ve arkadaşları tarafından rapor edilmiştir [19]. Orta derecede zekâ geriliklerinin en sık rastlanan genetik nedeni olan down sendromunun canlı doğumlar arasındaki sıklığının 1/800 dolaylarında olduğu bilinmektedir ve bu oranın anne yaşına bağlı olarak arttığı belirtilmektedir [19;20]. Günümüzde bu hastalıkların teşhisi için daha önceki hastaların literatürde tanımlanan fiziksel tarifleri veya fotoğrafları ile karşılaştırarak bir sonuca varılmaya çalışılmaktadır [19;21]. Kesin sonuca ulaşamadığı durumlarda çeşitli hormon testleri, sitogenetik testler uygulanmaktadır. Fakat testlerin çok maliyetli olması ve sonuca geç ulaşılması sebebiyle en son uygulanan teşhis yöntemi olarak kullanılmaktadır. Dismorfik hastalıkların birçoğu şekil itibariyle tanımlanabildiğinden şekil karşılaştırılması dismorfik hastalıkların klinik ön tanısında önemli rol oynamaktadır.

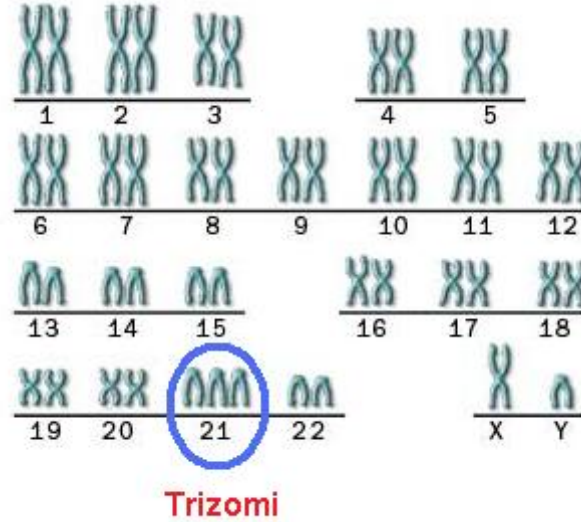
Trizomi 21, down sendromu ya da mongolizm olarak bilinmektedir. Genetik düzensizlikler sonucu insanda fazladan bir 21. Kromozomun bulunması durumu sonucu oluşmaktadır. Diğer bir şekilde ifade edilir ise Down sendromunda 46 adet olması gereken kromozom 47 adet kromozom olarak bulunmaktadır. Down sendromu zihinsel ve fiziksel gelişiminin gecikmesine neden olmaktadır. Çoğu zaman hastalığın oluş sebebi akraba evliliklerinden kaynaklanmaktadır. Bunun yanı sıra ileri yaşta hamilelik sonucu doğan bebeklerde de down sendromu görülme riski çok yüksek olarak bildirilmektedir [19;20].

2.1.5.1 Down sendromunun oluşumu

İnsanda 23 çift olmak üzere toplam 46 adet kromozom bulunmaktadır. Kromozomların yarısı anneden diğer yarısı ise babadan gelmektedir. 22 adet kromozom kadın ve erkeklerde aynı olarak bulunmaktadır. Bu kromozomlar bedensel faaliyetleri kontrol ederler ve otozomal kromozomlar olarak

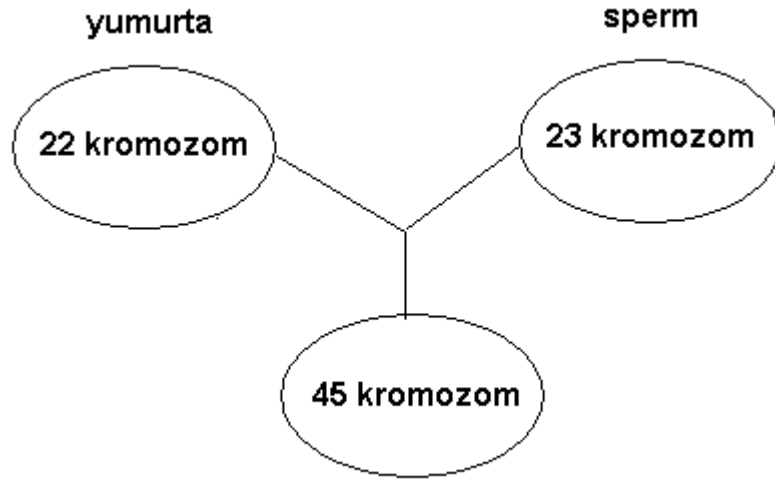
adlandırılmaktadır. 23. kromozom ise cinsiyeti belirlediğinden seks (cinsiyet) kromozomu olarak isimlendirilmektedir. Bir kromozom çiftindeki anneden ve babadan gelen kromozomlar aynı geni kodlamaktadırlar. Bu bilgiler aynı geni kodlamasına rağmen çeşitli nedenlerle farklı olabilmektedir.

Erkeklerde testis ve kadındaki yumurtalıklarda yer alan üreme hücreleri dışında vücuttaki tüm hücreler mitoz bölünme ile çoğalmaktadırlar ve 23 çift olmak üzere toplam 46 adet kromozom içermektedirler. Testis ve yumurtalıkta ise mayoz bölünme olmaktadır ve hücrelerin genetik materyalleri ikiye ayrılmaktadır. Yani sperm ve yumurta 23 çift değil 23 tek kromozom içerir. Sperm hücresi 22 otozomal kromozomla birlikte X ya da Y kromozomu içerirken, kadındaki döllenmeye hazır yumurta hücresi 22 otozomal kromozom ve bir adet X kromozomu içermektedir. Sonuçta döllenme olup sperm ile yumurta birleştiğinde spermden gelen 23 tek kromozom ile yumurtadan gelen 23 tek kromozom birleşmekte ve ortaya çıkan embriyoda 23 çift yani 46 adet kromozom olmaktadır. Down sendromunda hücrelerde 46 adet değil 47 adet kromozom vardır ve fazla olan kromozom 21. kromozomdur. Başka bir deyişle 21. kromozomdan 2 değil 3 tane vardır. Üç adet kromozom yapısı şekil 2.1’de görülmektedir.



Şekil 2.1 Üç adet 21. Kromozom gösterimi [22]’den değiştirilmiştir.

Hücre bölünmesi sırasında pek çok hata ortaya çıkabilir. Mayoz bölünme sırasında kromozom çiftleri birbirinden uzaklaşarak farklı hücelere dağılmaktadır. Buna ayrılma ya da disjunction adı verilmektedir. Bazı durumlarda bir çift kromozom ayrılmaz ve kromozom çifti beraberce bölünen hücelerden birine geçmektedir. Nondisjunction ya da ayrılmama adı verilen bu durum olduğunda bölünme sonrası ortaya çıkan hücelerden birinde 22 kromozom varken diğerinde 24 kromozom bulunmaktadır. Eğer bu eksik ya da fazla sayıda kromozom taşıyan hücre döllenme olayına katılır ve normal sayıda kromozom içeren bir sperm ya da yumurta ile döllenirse sonuçta ortaya çıkan embriyoda normalden farklı sayıda kromozom olacaktır. Ayrılmama en sık 21. kromozomda olmaktadır. İki tane 21. kromozom içeren 24 kromozomlu bir üreme hücresi normalde olması gerektiği gibi 1 tane 21. kromozom taşıyan bir üreme hücresi ile birleştiğinde embriyoda 3 tane 21. kromozom bulunmaktadır. Bu durum Trizomi 21 yani Down sendromudur. Tam tersi durumda hiç 21. kromozom içermeyen 22 kromozomlu bir sperm ya da yumurta, normal yapıda bir sperm ya da yumurta ile birleştiğinde sadece 1 adet 21. kromozomu olan toplam 45 kromozomlu bir embriyo oluşmaktadır. Buna monozomi adı verilir. Monozomi varlığında gebelik genelde düşükle sonuçlanmaktadır. Monozominin yapısı şekil 2.2’de görülmektedir.



Şekil 2.2 Monozominin yapısı

Ayrılmama en sık 21. kromozomda görülmekle birlikte 13. ve 18. kromozomlarda ve hatta çok nadir olarak diğer kromozomlarda da görülebilmektedir. Ayrılmamaya bağlı Down sendromu olgularının %90'ında iki tane 21. kromozom taşıyan anormal hücrenin sperm değil yumurta hücresi olduğu saptanmıştır. Yumurtada meydana gelen ayrılmamanın nedeni bilinmemektedir ve anne yaşı ile kuvvetli bir ilişkisi olduğu kabul edilmiştir. Günümüzde hala ayrılmamanın nedenleri ve zamanı ile ilgili çok sayıda araştırma devam etmektedir [19].

Trizomi 21 olgularının %1–4'ünde durum daha farklıdır. Fazla olan 21. kromozom serbest halde değil başka bir kromozoma eklenmiş halde bulunur. Bu duruma Robertsonian Translokasyon'u (yer değiştirmesi) adı verilir. Genelde 14. ve 21. kromozomlar arasında görülür. 14. kromozomda bir kırık oluşur ve fazla olan 21. kromozom buraya yapışır. Karyotip olarak bireyde 46 adet kromozom olmasına karşın 14. kromozom normalden daha büyüktür. Bazen 21. kromozomun tamamı değil bir kısmı ayrışmaz ve 14. kromozoma eklenir. Bu duruma kısmi (parsiyel) Trizomi 21 adı verilmektedir. Translokasyon kalıtsal olabilir. Dolayısıyla translokasyon saptanan bireylerin anne babaları da incelenmeli ve karyotip analizi yapılarak taşıyıcı olup olmadıkları belirlenmelidir.

Bir diğer Down sendromu türü de mosaisizmdir. Bu bireylerin hücre yapıları birbirinden farklıdır. Bazı hücreler normal sayıda kromozom içerirken, bazı hücrelerde trizomi 21 bulunmaktadır. Hücresel mosaisizmde aynı türdeki değişik hücrelerde farklı yapıda hücreler bulunmaktadır. Örneğin deri hücrelerinin bazıları normal bazıları anormal olarak görülmektedir. Doku mosaisizminde ise farklı hücre gruplarının tamamı anormal olarak görülmektedir. Örneğin kan hücrelerinin tamamı normal olarak görülür iken, deri hücrelerinin tamamı anormal olarak görülmektedir.

2.1.5.2 Down sendromunun teşhisi

Down sendromu genellikle doğum öncesi veya sonrasında tanımlanabilmektedir. Doğum öncesinde anne karnında alınan sıvı ile üçlü tarama testi yapılarak teşhis yapılabilmektedir. Doğum sonrasında ise genellikle bebeğin fiziksel özelliklerine dayandırılarak teşhis yapılabilmekte veya genetik testler yapılabilmektedir. Bu bebekler doğduklarında farklı bir yüz görünümüne sahiptirler. Başları ufak, kafanın arkası yassı, ense kısa ve geniş olmaktadır. Burun kökü yassı olur, kulaklar normalden düşük bir seviyede durur ve gözler birbirinden ayrık ve çekik görünür. Dil, normal konuşmayı önleyecek kadar genişlemiştir. Ensende genellikle boğumlar vardır. Eller geniş, parmaklar kısa, tombul ve avuç içlerinin birinde ya da her ikisinde "Simian çizgisi" denilen tek bir çizgi sıklıkla bulunmaktadır. Ellerin serçe parmakları genellikle içe doğru kıvrımlı olmaktadır. Mental retardasyon bulunmaktadır. Çocukluk dönemlerinde solunum hastalıkları, kalp bozuklukları nedeniyle ölümlere rastlanabilmektedir. Yaşam süreleri geçmiş yüzyılda yirmili yaşlarına seyrek olarak ulaşabilirken, günümüzde iyi bakım sonucunda bu yaş oldukça yükselmiştir.

Down sendromunun getirdiği fiziksel özelliklerin bir kısmı ya da tamamı şöyledir: Epik antik deri katlanmasıyla gözlerin kenarlarında eğik göz çizgileri, kas tonusu düşüklüğü (kas hipotonisi), basık burun kemeri, tekli el çizgisi, küçük ağız boşluğundan dolayı sarkan ve genişlemiş dil, kısa boyun, gözün irisinde fırça izi benekleri olarak bilinen beyaz noktalar, konjenital kalp defektleri, ayak başparmağı ile ikinci parmak arasında fazla boşluk, beşinci el parmağında esneklik ve dirsekte yüksek döngü görülmektedir.

Down sendromunun getirilerinden biri de orta düzeyli 50–70 IQ (Intelligence Quotient – Zeka derecesi) ile 35–50 IQ arasında değişebilen zeka geriliği olarak görülmektedir [23]; bu derece Mozaik Down sendromunda 10–30 olarak görülmektedir. Down sendromunun getirilerine ek olarak, vücut sistemini etkileyen ciddi anomaliler de bulunabilmektedir.

Daha önce de belirtildiği gibi klinik ön tanı, referans kitaplarındaki örnek resimlerden karşılaştırma yolu ile veya hekimden hekime değişiklik gösterebilen tecrübe faktörü sayesinde konulabilmektedir. Tez kapsamında oluşturduğumuz yüz tanıma işlemini gerçekleştiren bilgisayar programı ile Down sendromu endikasyonları bulunan bebeklerin yüz fotoğraflarının analizi yapılmış ve program vasıtasıyla klinik ön tanı konulması hedeflenmiştir.

2.2. Yüz Tanıma

Yüz tanıma işlemi tanınmak istenen yüzün veri tabanındaki tüm yüzlerle hangi oranlarda eşleştiğinin hesaplanması esasına dayanır. Tanıma işlemi ise sorgulanan resmin veri tabanındaki hangi yüze ait resimle daha çok eşleştiğinin bulunması ile sağlanmaktadır. Günümüzde yüz tanıma ile yapılan ve her geçen gün geliştirilen birçok uygulama bulunmaktadır. Yüz tanımaya olan ilgi yeni çalışmaları gündeme getirmekte ve çeşitli tanıma algoritmaları üretilmektedir. Aşağıda algoritmalarından en çok kullanılan Temel Bileşen Analizi (Principal Component Analysis) ve çalışmamızda kullandığımız Elastik Yüz Demet Grafik Metodu (Elastic Face Bunch Garph Metot) hakkında genel bilgi verilecektir.

2.2.1 Temel Bileşen Analizi (TBA)

TBA yüz tanıma ve yüz doğrulamada en sık kullanılan alt-uzay yöntemidir [24]. TBA'nde yüz imgelerinin dağılımını en iyi betimleyen doğrusal izdüşümleri hesaplanır [25]. Verilen bir eğitim setindeki yüzlerin n boyutlu vektörler olduğu düşünülürse bu vektörler arasındaki maksimum varyans değerine dayalı t boyutlu bir alt örnek uzayı elde etmeye çalışan bir algoritmadır [26].

Tahmin edilebileceği üzere yeni oluşturulan bu alt uzay vektörleri gerçek test kümesi vektörlerinden çok daha küçük boyutlu olmaktadır [27]. TBA yöntemi olarak en çok kullanılan yöntem Özyüzler (eigenfaces) yöntemidir [24]. Bu yöntemde yüzler arasındaki farkları en iyi şekilde ifade eden bir yüz uzayı oluşturulmaktadır.

Bu yüz uzayının öz vektörleri elde edilmektedir ve bu öz vektörler özyüz olarak isimlendirilmektedir. Özyüzler, eğitim kümesinde yer alan yüzlerin temel bileşenlerini oluşturmaktadır. Tanıma olayı yeni bir yüzün elde edilen bu yüzler tarafından oluşturulmuş yüz uzayına projeksiyonu ile gerçekleşmektedir. Projeksiyon sonucu elde edilen konum diğer yüzlerin konumları ile karşılaştırılmaktadır. Eğer yeterince yakın bir yüz bulunabilirse bu sisteme daha önceden verilmiş bir yüzün tekrar verildiğini göstermektedir. Eğitim setinde yeterince yakın bir yüz bulunamaması durumunda istenirse yüz sisteme tanıtılarak eğitim kümesinin bir elemanı haline getirilmektedir. Böylece sistem yeni yüzü öğrenmiş olacaktır. TBA'nde amaç piksel değerleri birbirinden bağımsız yani birbirinden lineer olarak türetilmeyecek görüntülerden oluşan bir set elde etmektir. Yüz tanıma gibi bir uygulamada ise gerekli bilginin büyük kısmı görüntü pikselleri arasındaki yüksek düzey ilişkilerde saklanmaktadır [28].

2.2.2 Elastik Yüz Demet Grafiği (EYDG)

Elastik Yüz Demet Grafiği (EYDG), tutarlı nesne görüntülerinin görüntü düzleminde çevirme, ölçekleme, dönme ve deforme olma eğiliminde olduklarını yansıtan önemli yapı çekirdeğine sahip bir yöntemdir.

Her hangi bir sınıftaki nesnelerin tümü için ortak yapıya özgü bilgilere sahip olmak önemlidir. Yüz demet grafiğinde sınıfa özgü bilgi, demet grafikler şeklinde olmakta, her bir poz için bir tane bulunmaktadır ve bunlar makul sayıda farklı yüzlerden oluşan yığınlar halindedir.

Uygun bir fucial nokta setinden jet numuneler alınmaktadır (yüzler, göz, dış çizgiler, vb. üzerine yerleştirilmiştir). Demet grafikler, her bir fucial nokta için, farklı bir numune yüzden bir jetin seçilebildiği, böylece oldukça uyarlanabilir bir model yaratılabilen kombine edici varlıklar olarak düşünülmektedir.

2.2.2.1 Gabor dalgacıkları ve jetler

Yerel özelliklerin temsili, Gabor dalgacık dönüşümüne bağlı olmaktadır. Gabor dalgacıkları, bir Gauss zarf fonksiyonu tarafından kısıtlanan düzlem dalgaları şeklindeki biyolojik açıdan motive olmuş kıvrım çekirdekleri olarak tanımlanmaktadır [29]. Bir görüntü pikselinde yer alan farklı yönelmelerdeki ve frekanslardaki çekirdekler için kıvrım katsayıları setine bir jet denir.

Bir jet, verilen bir piksel

$\vec{x} = (x, y)$.. çevresinde bir görüntüdeki $I(\vec{x})$ küçük bir gri değerler parçasını tarif eder.

$$I_i(\vec{x}) = \int I(\vec{x}') \psi_j(\vec{x} - \vec{x}') d^2 \vec{x}' \quad (2.1)$$

Bir Gabor çekirdeğiyle gabor dalgacığı Denklem 2.2'de görüldüğü gibi elde edilmektedir.


$$\psi_j(\vec{x}) = \frac{k_j^2}{\sigma^2} \exp\left(-\frac{k_j^2 x^2}{2\sigma^2}\right) \left[\exp(i \vec{k}_j \cdot \vec{x}) - \exp\left(-\frac{\sigma^2}{2}\right) \right] \quad (2.2)$$

Bir Gauss zarf fonksiyonu tarafından kısıtlanan dalga vektörüne \vec{k}_j sahip düzlem dalgaları şeklindedir. 5 farklı aralıklı frekans dizisini, $v = 0, \dots, 4$ ve 8 yönelme, indeks $\mu = 0, \dots, 7$ ile indeks $j = \mu + 8v$.

$$\vec{k}_j = \begin{pmatrix} k_{jx} \\ k_{jy} \end{pmatrix} = \begin{pmatrix} k_v \cos \varphi_\mu \\ k_v \sin \varphi_\mu \end{pmatrix}, k_v = 2^{-v+2/2}, \varphi_\mu = \mu \frac{\pi}{8} \quad (2.3)$$

Bu örnekleme, frekans boşluğunda bir bandı eşit olarak kapsamaktadır. Gauss'un σ / k genişliği, $\sigma = 2 \pi$ parametresiyle kontrol edilir. Denklem (2.2) parantezindeki ikinci terim, çekirdekleri DC'den bağımsız hale getirmektedir, başka bir deyişle, $\int \psi_j(\vec{x}) d^2 \vec{x}$ integrali ortadan kalkmaktadır. Bu, bir dalgacık dönüşümü olarak bilinmektedir, çünkü çekirdekler ailesi kendi kendine benzer, çekirdeklerin

tümü, genleşme ve dönüş yoluyla bir ana dalgacıktan oluşturulmaktadır. Buna göre bir yüzün grafik temsilini gösteren grafik şekil 2.3'de gösterilmektedir.



Şekil 2.3 Bir yüzün grafik temsili [30]'dan değiştirilmiştir.

Gabor dalgacık dönüşümüne bağlıdır, başka bir deyişle, bir dizi dalgacık çekirdekleri setine sahip bir kıvrımdır. Bunlar, bir Gauss zarf fonksiyonunun kısıtlandığı düzlem dalgaları şeklindedirler.

Bir jet, I , bir görüntü noktası için elde edilen 40 karmaşık katsayı seti I_j olarak tanımlanmaktadır ve Denklem 4'de ki gibi ifade edilebilmektedir.

$$I_j = a_j \exp(i\phi_j) \quad (2.4)$$

Bu pozisyonla yavaşça değişiklik gösteren büyüklükler $a_j(\vec{x})$ olarak yazılabilmekte, çekirdeklerin uzamsal frekansı veya dalga vektörü \vec{k}_j ile yaklaşık olarak tespit edilen bir hızda dönen safhalar ise $\phi_j(\vec{x})$ olarak yazılabilmektedir.

Gabor dalgacıkları, bir veri formatı olarak sağlamlıkları ve biyolojik ilintileri nedeniyle seçilmektedir. DC içermedikleri için, görüntüde değişiklik gösteren parlaklığa karşı sağlamlık sağlarlar. Değişiklik gösteren kontrasta karşı sağlamlık, jetleri normalleştirerek elde edilmektedir. Yer ve frekans bakımından sınırlı yer belirtme ise aktarmaya, çarpıklığa, dönmeye ve ölçeklemeye karşı belirli oranda

bir sađlamlık kazanılmaktadır. Aktarmayla sadece faz büyük ölçüde deđiřir. Bu faz deđiřikliđi göz ardı edilebilmektedir veya yerinden çıkarmayı tahmin etmek için kullanılabilir. Büyük çekirdeklerin bir dezavantajı, arka plan deđiřikliklerine karşı hassasiyetleridir. Ne var ki, nesnenin dış çizgileri bilindiđi takdirde, arka plan etkisinin bastırılabilir deđiřtirilmektir [31]. Son olarak, Gabor dalgacıkları, omurgalı hayvanların görsel kabuklarında yer alan basit hücrelerin alıcı alanlarıyla benzer řekle sahiptirler [31] ve istatistiksel olarak dođal sahnelerin görüntülerinden nitel açıdan elde edilebilmektedir [32].

2.2.2.2 Jetlerin karşılaştırılması

Faz rotasyonu sebebiyle, birbirlerinden sadece birkaç piksel ayrı olan görüntü noktalarından alınan jetler, çok farklı katsayılara sahip olmaktadır, fakat neredeyse aynı lokal özelliđi temsil etmektedirler. Bu durum eřleřtirme için ciddi sorunlara yol açabilmektedir. Dolayısıyla ya fazı göz ardı etmek, ya da deđiřikliđini açıkça telafi etmek gerekmektedir. Ařađıda kullanılan benzerlik fonksiyonu Denklem 2.5'de görölmektedir.

$$S_a(I, I') = \frac{\sum_j a_j a'_j}{\sqrt{\sum_j a_j^2 \sum_j a'^2_j}} \quad (2.5)$$

fazı göz ardı etmektedir. Sabit bir görüntü pozisyonunda alınan bir jet I ile $\vec{x}, S_a(I, I'(\vec{x}))$ deđiřken pozisyonda alınan jetler $I' = I'(\vec{x})$ büyük fazlar oluřturan yerel elverişli řartlara sahip pürüzsüz bir fonksiyondur, rasgele eđim iniři gibi basit arařtırma metodlarıyla hızlı ve güvenilir uyuma yol açmaktadır.

Faz kullanımının potansiyel iki avantajı vardır. Birincisi; meydana geldikleri takdirde, benzer büyüklüklere sahip modeller arasında ayırım yapmak için faz bilgileri gerekir ve ikincisi; faz, konumla birlikte hızla deđiřiklik gösterdiđi için, bir görüntüde dođru jet konumlandırması için bir araç sağlamaktadır. İki jet I ve I' ün küçük nispi yerinden çıkarma \vec{d} ile nesne konumlarına atıf yaptıđı varsayılırsa, safha deđiřiklikleri $\vec{d} \vec{k}_j$ terimleri ile yaklaşık olarak telafi edilebilmekte ki bu da faza

karşı hassas bir benzerlik fonksiyonuna yol açmaktadır. Denklem 2.6'da bu eşitlik görülmektedir.

$$S_{\phi}(I, I') = \frac{\sum_j a_j a'_j \cos(\phi_j - \phi'_j - \vec{d} \cdot \vec{k}_j)}{\sqrt{\sum_j a_j^2 \sum_j a'^2}} \quad (2.6)$$

Bu denklemi hesaplamak için, yerinden çıkarma \vec{d} tahmin edilmemektedir. Bu, aşağıdaki bölümde açıklanan şekilde, Taylor uzantısında S_{ϕ} ü maksimize ederek yapılabilmektedir. Aslında yerinden çıkarma bilgileri sağladığı ikinci benzerlik fonksiyonunun büyük bir avantajı budur. Benzerlik ve tahmin edilen yerinden çıkarma profilleri, bölüm 2.3.4 anlatılmaktadır.

2.2.2.3 Yerinden çıkarma tahmini

Yerinden çıkarma vektörünü \vec{d} tahmin etmek amacıyla, eşitsizlik fonksiyonu için kullanılan bir metod olarak kabul edilmektedir [33]. Buradaki fikir, Taylor uzantısında benzerliği S_{ϕ} ile maksimize edilmektedir. Denklem 2.7 'de bu eşitlik yazılacak olursa aşağıdaki gibi elde edilir;

$$S_{\phi}(I, I') = \frac{\sum_j a_j a'_j [1 - 0.5s(\phi_j - \phi'_j - \vec{d} \cdot \vec{k}_j)^2]}{\sqrt{\sum_j a_j^2 \sum_j a'^2}} \quad (2.7)$$

$\frac{\partial}{\partial d_x} S_{\phi} = \frac{\partial}{\partial d_y} S_{\phi} = 0$ ü belirlemek ve \vec{d} için çözmek, aşağıdaki denklem 2.8 i oluşturmaktadır:

$$S_{\phi}(I, I') = \begin{pmatrix} d_x \\ d_y \end{pmatrix} = \frac{1}{\Gamma_{xx} \Gamma_{yy} - \Gamma_{xy} \Gamma_{yx}} \times \begin{pmatrix} \Gamma_{yy} & -\Gamma_{yx} \\ -\Gamma_{xy} & \Gamma_{xx} \end{pmatrix} \begin{pmatrix} \phi_x \\ \phi_y \end{pmatrix} \quad (2.8)$$

Eğer denklem 2.9 ile $\Gamma_{xx} \Gamma_{yy} - \Gamma_{xy} \Gamma_{yx} \neq 0$ ise,

$$\Phi_x = \sum_j a_j a'_j k_{jz} (\phi_j - \phi'_j), \quad (2.9)$$


$$\Gamma_{xy} = \sum_j a_j a'_j k_{jz} k_{jy}, \quad (2.10)$$

$\phi_y, \Gamma_{xx}, \Gamma_{yz}, \Gamma_{yy}$ tekabül eden bir şekilde tanımlanmaktadır. Ayrıca, bunları $\pm\pi$ dizisine yerleştirmek için safha farklarını $\pm 2\pi$ ile düzeltmek gerekebilmektedir.

Bu denklem, Garbor çekirdekleri oldukça örtüşecek kadar yakın nesne konumlarından alınan iki jet arasındaki farkı veya yerinden çıkarmayı tahmin etmek için anlaşılması kolay bir metot sağlamaktadır. Daha fazla değişiklik olmaksızın, bu denklem, $k_0 = \pi/2$ için iki piksel olan en yüksek frekans çekirdeğinin dalga boyunun yarısına kadar yerinden çıkarmaları tespit edilebilmektedir. Dizi, sadece düşük frekanslı çekirdekleri kullanarak arttırılabilmektedir. En büyük çekirdekler için, tahmin edilen yerinden çıkarma, 8 piksel olabilmektedir. Daha sonra, bir sonraki daha yüksek frekans seviyesine ilerlenebilir ve sonuç düzeltilebilmektedir. Sonraki daha yüksek frekansa geçerken, daha düşük frekans seviyesinde tahmin edilen yerinden çıkarmadan ifade edilen beklenen faz farklarına mümkün olduğunca uymak amacıyla, daha yüksek frekanslı katsayıların safhaları, 2π 'nin katlarıyla düzeltilmelidir. Bu düzeltme, π 'den daha büyük mutlak faz farklarına yol açabilmektedir. Birinci yerinden çıkarma tahmini için kullanılan frekans seviyelerinin sayısına odak olarak varsayabiliriz. 1'lik bir odak, sadece en düşük frekans seviyesinin kullanıldığını ve tahmin edilen yerinden çıkarmanın 8 piksel kadar fazla olabileceğini belirtmektedir. 5'lik bir odak, beş seviyenin tümünün de kullanıldığını ve farkın sadece 2 piksele kadar olabileceğini belirtmektedir. Her halükarda, beş seviyenin tümü de eninde sonunda yukarıda tarif edilen tekrarlanan süreçte kullanılmaktadır.

Bir jetin I bir görüntüde nokta \vec{x}_0 yakınında doğru bir şekilde yerleştirileceği varsayılmaktadır. I ü $I_0 = I(\vec{x}_0)$ ile kıyaslamak, $\vec{d}_0 = \vec{d}(I, I(\vec{x}_0))$ ün tahmin edilen yerinden çıkarılmasını sağlamaktadır.

Daha sonra, bir jet I_1 , pozisyon $\vec{x}_1 = \vec{x}_0 + \vec{d}_0$ den alınır ve yerinden çıkarma yeniden tahmin edilmektedir. Fakat yeni konum, doğru pozisyona daha yakın olduğu için, yeni yerinden çıkarma \vec{d}_1 , daha küçük olacaktır ve daha yüksek bir odakla daha doğru bir şekilde tahmin edilebilmekte, eninde sonunda alt piksel doğruluğuna yaklaşılmaktadır. Şekil 2.5’de Yüz Demet Grafiği görülmektedir.



Şekil 2.4 Yüz Demet Grafiği (YDG) [35] ‘den değiştirilmiştir.

Yüz demet grafiği genel olarak bir yüzler temsili görevi görmektedir. Yüzlerin görünümünde olası tüm varyasyonları kapsamak üzere tasarlanmaktadır. Yüz demet grafiği, bazı yüz grafiklerinden gelen bilgileri bir araya getirmektedir. Boğumları, demetler adı verilen jet dizileriyle ve kenarları ise, uzaklık vektörlerinin ortalamalarıyla etiketlenmektedir. Bir görüntüyle karşılaştırma sırasında, her demette en iyi uyan ve gri gölgeyle belirtilen jet, el ile olarak seçilmektedir.

2.2.2.4 Elastik demet grafik eşleştirmeyle yüz temsilleri oluşturmak

Elastik demet grafiğini oluşturmanın en kolay yolu el ile oluşturmaktır. Sistem için başlangıç düzeyinde grafikler oluşturmak için bu metot kullanılmaktadır.

Farklı pozlar için grafikteki hangi boğum çiftlerinin birbirlerine karşılık geldiklerini belirtmeyi amaçlayan, her poz için bir grafik elde edilmektedir. Sistem, bir elastik yüz demetine sahip olduğunda (elle tanımlanmış sadece bir modelden oluşur), yeni görüntüler için grafikler, elastik demet grafik eşleştirmeyeyle otomatik olarak oluşturulabilmektedir. Başlangıç düzeyinde, yüz demet grafiği sadece birkaç yüzden oluştuğunda, meydana gelen eşleşmeleri gözden geçirmek ve düzeltmek gerekir, fakat yüz demet grafiği yeterince zengin hale geldiğinde (yaklaşık 70 grafik), eşleştirmeye güvenilebilmekte ve geniş model grafiği galerileri otomatik olarak üretilebilmektedir.

2.2.2.5 Grafiklerin elle tanımı


Grafiklerin elle tanımı üç adımda yapılır. Birinci adımda verilen bir görüntü için bir dizi fudicial noktayı işaretleriz. Bunların birçoğu, sol ve sağ gözbebeği, ağzın köşeleri, burnun ucu, kulakların üstü ve altı, başın üstü ve çenenin ucu gibi konumlandırılması kolay, iyi tanımlanmış yüzün kritik noktalarına yerleştirilmektedirler. Bu noktalar, elle yerleştirmeyi kolay ve güvenilir hale getirmek amacıyla seçilmektedir. İlave fudicial noktalar, yerleştirilmesi kolay belirli fudicial noktaların ağırlık merkezinde yer almaktadır. Bu, iyi tanımlanmış özelliklerin eksik olduğu bölgelerde fudicial noktaların otomatik olarak seçilmesine izin verir. Örneğin yanaklarda veya alın kısmında otomatik olarak seçilebilmektedir. Daha sonra, kenarlar, fudicial noktalar arasında çizilirler ve kenar etiketleri, boğum pozisyonları arasındaki farklar olarak otomatik bir şekilde hesaplanırlar. Son olarak, Gabor dalgacık dönüşümü, boğumlar için jetler sağlamaktadır.

Genel olarak, fudicial noktalar seti, yüzü eşit olarak kaplamalıdır. Fakat göreve bağlı olarak, belirli bölgeleri ilave boğumlarla vurgulamak uygun olabilmektedir. Örneğin, yüzü bulmak için, ana çizgiler üzerine daha fazla boğum yerleştirilir, çünkü homojen arka planla, dış çizgiler, yüzleri bulmak için iyi bir işaret teşkil etmektedir.

Diğer yandan, yüzü tanımak için, tanımayla ilgili önemi sebebiyle, yüzlerin içine daha fazla boğum yerleştirilir. Yoğun bir setten boğumları seçmenin daha sistematik bir yolu [29;34]' de sunulmaktadır. Daha fazla boğum, daha iyi sonuçlar verme eğilimindedir, çünkü daha fazla bilgi kullanılmaktadır, fakat eğer boğumlar çok yakın ise ve çekirdekler arasındaki örtüşme sebebiyle karşılık gelen Gabor katsayıları oldukça ilişkili hale gelirse, bu etki doymaktadır. Öte yandan, boğumların sayısı ile doğrusal olarak artmaktadır. Bu nedenle, boğumlar için en elverişli sayı, tanıma performansı ve hız arasındaki bir ayarlama olacaktır.

2.2.2.6 Eşleştirme prosedürü

Bir inceleme görüntüsü üzerinde Elastik Demet Grafik Eşleştirmenin amacı, fiducial noktaları bulmak ve böylece grafikten tanımlanan yüz demet grafiği ile benzerliği maksimize eden bir grafiği çekip çıkarmaktır. Uygulamada makul bir süre içinde optimuma yaklaşmak amacıyla düzgün bir algoritma uygulanmaktadır. Burada tarif edilen eşleştirme planı, sadece bir yüz demet grafiğinin gerekebilmesi için bilinen pozlara ve yaklaşık olarak standart büyüklüğe sahip yüzler gerekmektedir. Yüz demet grafiklerinin oluşturulması ile ortalama bir yüz demet grafiği ortaya çıkmaktadır. Sonuçta meydana gelen grafiğe görüntü grafiği adı verilir ve görüntünün bireysel yüzünün bir temsili olarak saklanmaktadır.



Şekil 2.5: Farklı pozlar için nesne uyarlamalı ızgaralar [35'den değiştirilmiştir].

Boğumlar, tekabül eden yüz demeti grafiklerine karşı elastik grafiği eşleştirerek otomatik olarak yerleştirilmektedirler. Yüzü güvenilir bir şekilde bulmak için dış çizgiler üzerinde birçok boğumla normalleştirme aşaması için kullanılan şekilde, büyüklük ve ızgara bakımından büyük farklılık gösteren iki orijinal, soldaki iki görüntü tarafından gösterilmektedir. Sağdaki görüntüler, zaten normal büyüklüğe yeniden ölçeklenmektedir. Bunların ızgaraları, yüzde daha fazla boğuma sahiptir ki bu durum tanımak için daha uygun olmaktadır. Görülebilir ki, genel olarak, eşleştirme, fiducial noktaları oldukça doğru bir şekilde bulur. Fakat yanlış eşleştirmeler meydana gelir, örneğin, sakallı adam için çene, doğru bir şekilde gösterilmemektedir.

2.3 Yapay Sinir Ağları (YSA)

YSA insan beynindeki sinirlerin çalışmasını taklit ederek bilgisayarlara düşünme, öğrenme, genelleme yapma gibi özelliklerin eklenmesini sağlamak amacıyla oluşturulmuş bilgi sistemleridir [38]. Genel anlamda YSA beynin bir işlevini yerine getirmek için tasarlanmış ağ modelleridir. YSA öğrenme algoritmaları ile öğrenmeyi gerçekleştirdikten sonra sinirler arasındaki bağlantı ağırlıkları sayesinde genelleme yapma yeteneğine sahiptirler [38;39].

İlk ticari YSA'nın geliştiricisi olan Dr. Robert Hecht-Nielsen'in yapay sinir ağı tanımı şöyledir : " YSA, dışarıdan gelen girdilere dinamik olarak yanıt oluşturma yoluyla bilgi işleyen, birbiriyle bağlantılı basit elemanlardan oluşan bilgi işlem sistemidir." YSA da en çok tanınan Teuvo Kohonen'nin YSA tanımı ise literatür de şu şekilde geçmektedir: "YSA, paralel olarak bağlantılı ve çok sayıdaki basit elemanın, gerçek dünyanın nesneleriyle biyolojik sinir sisteminin benzeri yolla etkileşim kurduğu hiyerarşik bir organizasyonudur" [40].

2.3.1 YSA'nın tarihçesi

İnsan beyninin ve düşünme yeteneğinin taklit edilmesi isteği oldukça eskiye dayanmaktadır. Bu konudaki ilk açıklayıcı teori geliştirme denemeleri antik Yunan

düşünürleri olan Plato (İ.Ö. 427-327) ve Aristoteles'e (İ.Ö. 384-322) kadar uzanmaktadır [41]. Daha sonra ise 18. yüzyıl düşünürü olan Descartes (1596-1650) insanın düşünme yeteneğiyle ilgilenmiştir. Beynin üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve beynin nörofiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece, YSA denen günümüz bilgisayarlarının algoritmik hesaplama yöntemlerinden farklı bir bilim alanı ortaya çıkmıştır [42].

YSA hesaplama modelinin temelleri 1940'ların başında araştırmalarına başlayan W.S. McCulloch ve Pitts'in, çalışmaları 1940 yılından sonra hızlı bir şekilde ilerlemiştir. 1940 yılından önce de birtakım çalışmalar yapılmıştır ama bu çalışmalar mühendislik açısından bir nitelik taşımamaktadır. YSA'nın temelleri ilk 1943 yılında yayınladıkları bir makaleyle atılmıştır. McCulloch ve Pitts YSA hakkında yapılan çalışmaları mühendislik alanına kaydırmış ve günümüzdeki YSA'nın temelleri oluşturmuştur [43]. 1949 yılında Donald Hebb, YSA için günümüzdeki birçok öğrenme kuralının da temelini oluşturan "Hebbian Öğrenme" adı verilen öğrenme kuralını geliştirmiştir. 1950'li yıllarda çalışmalar daha açık bir şekilde fark edilmiş ve 1951 yılında ilk nörobilgisayar üretilmiştir. Silikon teknolojisinin geliştirilmesi ile bu çalışmalar 1960'lı yıllarda oldukça önemli gelişmelere neden olmuştur [41;44]. 1954 yılında Farley ve Clark tarafından rassal ağlar ile adaptif üretme kavramı ortaya atılmıştır ve bu kavram daha sonraları 1958 yılında Rossenblatt ve 1961 yılında Cainaello tarafından geliştirilmiştir. Özellikle Rosenblatt tarafından geliştirilen algılayıcı model (perceptron) YSA tarihinde önemli bir gelişmeye öncülük etmiştir [45]. Çünkü bu model daha sonraları geliştirilecek ve YSA'nda devrim niteliğinde olacak olan çok katmanlı algılayıcıların temelini oluşturacaktır. Benzer şekilde Widrow ve Hoff ADALINE (Adaptive Linear Neuron) modelini ortaya attılar [44]. Bu aslında YSA'nın mühendislik uygulamalarına bağlanması için ilk adımlardan sayılmaktadır. Bu model, Rossenblatt'ın algılayıcı modeli ile aynı niteliklere sahip bir model olup sadece öğrenme algoritması daha gelişmiş bir modeldir [44]. Daha sonraki YSA modellerinin gelişmesine katkıda bulunmuş bir çalışmadır.

Adaptif öğrenmenin de temellerinden olan ve 1970'li yılların sonlarına doğru ortaya çıkan MADALINE modelleri bu çalışmaların neticesinde ortaya çıkmış ve gelecekte faydalı çalışmalara temel oluşturmuştur [41;44].

1960'lı yılların sonunda YSA çalışmaları duraklama devrine girmiştir. YSA'nın tarihinde bir duraklama devrine neden olan ise Yapay Zekâ biliminin o devirde önde gelen isimlerinden Minsky ve Pappert tarafından yazılan algılayıcılar (perceptrons) başlıklı bir kitap olmuştur [47]. Bu kitapta yazarlar özellikle YSA'na dayalı algılayıcıların bilimsel bir değerinin olmadığını ve doğrusal (lineer) olmayan problemlere çözüm üretilmediğini iddia etmişlerdir. Tezlerini kanıtlamak için ise meşhur XOR probleminin çözülmesini örnek göstermişlerdir. Bu örnek birçok kişiyi tatmin etmiş ve çalışmalar bir bıçak gibi kesilmiştir. YSA yapmak mümkün değildir inancı yükselmeye başlamıştır. Birçok bilim adamı buna inandığından çalışmalar yok denecek kadar azalmış ve sadece bir iki bilim adamı bu konuda çalışmaya devam etmiştir. XOR problemi çözülünceye kadar dikkatleri YSA'na çekmek mümkün olamamıştır. Bu zamana kadar yapılan çalışmaların kronolojik olarak aşağıdaki gibi listelenebilir [48];

- 1890 : İnsan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması
- 1911 : İnsan beyninin bileşenlerinin belirli bir düzenek ile sinir hücrelerinden (nöronlar) oluştuğu fikrinin benimsenmesi
- 1943 : Yapay sinir hücrelerinde dayalı hesaplama teorisinin ortaya atılması ve eşik değerli mantıksal devrelerin iliştilmesi
- 1949 : Biyolojik olarak mümkün olabilen öğrenme prosedürünün bilgisayarlar tarafından gerçekleştirilecek biçimde geliştirilmesi.
- 1956 – 1962 : ADALINE ve Widrow öğrenme algoritmasının geliştirilmesi.
- 1957 – 1962 : Tek katmanlı algılayıcının (perceptron) geliştirilmesi.
- 1965 : İlk makine öğrenmesi kitabının yazılması.
- 1967 – 1969 : Bazı gelişmiş öğrenme algoritmalarının (Grosberg öğrenme algoritması gibi) geliştirilmesi.
- 1969 : Tek katmanlı algılayıcıların doğrusal olmayan problemleri çözme yeteneklerinin olmadığını gösterilmesi.

Çalışmaların 1960 yılında sekteye uğraması ve gerekli mali desteklerin kesilmesine rağmen bazı bilim adamları çalışmalarına devam etmişlerdir. Özellikle Amari, Anderson, Cooper, Fukushima, Grossberg, Kohonen ve Hopfield gibi araştırmacıların çalışmaları 1980'li yıllara gelindiğinde meyvelerini vermeye başlamıştır [49;50]. 1972'lerde farklı disiplinlerde çalışan elektrik mühendisi Kohonen ve nöropsikolog Anderson “çağrışımlı bellek (associative memory)” konusunda hemen hemen birbirinin aynı çalışmaları yayınlamışlardır. Bu çalışmalar daha sonraları geliştirilecek olan öğretmensiz öğrenme kurallarının temelini oluşturmaktadır. Kohonen daha sonra “kendi kendine öğrenme nitelik haritaları” konusundaki çalışmasını yayınlamıştır [50]. 1960'lı yılların sonlarına doğru ortaya çıkan Grosberg YSA'nın psikolojik mantıksallığı ve mühendislik uygulamalarındaki kolaylığını göstermiştir. Carpenter ile Adaptif Rezonans Teorisini (ART) geliştirmiştir. Bu öğretmensiz öğrenme konusunda zamanının geliştirilmiş en karmaşık YSA olmuştur [51;52;53;54].

1970'lerin sonlarına doğru Fukushima görsel şekil ve görüntü tanıma amaçlı geliştirdiği Neocognitron modelini tanıtmıştır [55]. Bu model önceleri öğretmensiz öğrenme yapacak bir model olacak şekilde geliştirilmesine rağmen daha sonraları öğretmenli öğrenme yapacak hale getirilmiştir [55;56]. Bu çalışmaların neticesinde daha çok mühendislik uygulamaları görülmeye başlanmıştır. Çalışmalar biyolojik olarak doğruluktan daha çok sonuçların kullanılabilirliği konusuna ağırlık verilmiştir [57;58]. Neocognitron modelinde ara katmanlar kullanılarak öğrenme konusuna değinilmiştir. Fakat çalışmalar hesaplama işlemlerinin bilinmesini zorunlu kılıyordu. Bu çalışmalar günümüzde de etkin olarak yürütülmektedir.

1982 ve 1984 yıllarında Hopfield tarafından yayınlanan çalışmalar ile YSA'nın geliştirilebileceğini ve özellikle geleneksel bilgisayar programlama ile çözülmesi zor olan problemlere çözüm üretebileceğini göstermiştir [59]. Gezgin satıcı probleminin çözülmesi bunun en güzel örneklerindedir. Çalışmasını mühendislerin kolaylıkla anlayabileceği şekilde sunduğundan YSA'ya ilgi yeniden oluşmaya başlamıştır. Çalışmaların neticesi Hinton ve arkadaşlarının geliştirdikleri Boltzman makinesinin doğmasına yol açmıştır [60].

Aynı zamanlarda Rumelhart ve arkadaşları paralel programlama konularındaki çalışmalarını sonuçlandırmış ve 2 ciltlik bir eser ortaya koymuştur [61;62;63]. Bu eserlerinden çok katmanlı algılayıcı modelinin temellerini atmışlardır ve daha sonra bu modeli geliştirmişlerdir [64]. Çok katmanlı algılayıcıların bulunması YSA'nın tarihsel gelişimi bakımından çok önemli bir adımdır. Bu çalışmalardan sonra YSA'na olan ilgi yeniden ateşlemiştir. Yapılan seminerlerde çok sayıda makaleler sunuluyor ve yeni bir YSA dalgası bütün disiplinlerde kendini göstermeye başlamıştır. Çünkü tek katmalı algılayıcının çözemediği XOR problemi çok katmalı algılayıcıların bulunması ile çözülmüş ve YSA'nın çalışmadığını söyleyen bütün tezler çürütülmüştür. Aynı zamanlarda Parker ve Werbos tarafından da çok katmanlı algılayıcı ile ilgili olarak bazı çalışmalar yürütülmüştür [65;66]. Çok katmanlı algılayıcı sadece XOR problemini çözmekle kalmamış aynı zamanda Hopfield ve Boltzman makinelerinin sınırlamalarını da çözmüştür [59]. Bu da dikkatleri daha çok bu ağlar üzerine çekiyordu. 1988'de Broomhead ve Lowe, Radyal tabanlı fonksiyonlar (Radial Basis Functions-RTF) modelini geliştirmişlerdir [67]. Bu ağın çok katmanlı algılayıcılara alternatif olarak geliştirildiğini belirtmişlerdir. Özellikle filtreleme problemlerine oldukça başarılı sonuçlar üretmişlerdir. Daha sonra Specht bu ağların daha gelişmiş şekli olan Probabilistik Sinir Ağlarını (PNN) ve Genel Regrasyon Sinir Ağlarını (GRNN) geliştirmiştir [68;69]. 1987 yılından bu yana her yıl değişik sempozyumlarda ve konferanslarda YSA tartışılmakta ve yeni modeller ve öğrenme teknikleri ortaya atılmaktadır.

Günümüzde, YSA artık teorik ve laboratuvar çalışmaları olmaktan çıkmış ve günlük hayatta kullanılan sistemler oluşturmaya ve pratik olarak insanlara faydalı olmaya başlamışlardır.

1970 yılından sonra yapılan çalışmaların bazıları kronolojik olarak aşağıdaki gibi listelenebilir [48].

1969 – 1972 : Doğrusal ilişkilendiricilerin geliştirilmesi

1972 : Korelasyon Matris belleğinin geliştirilmesi

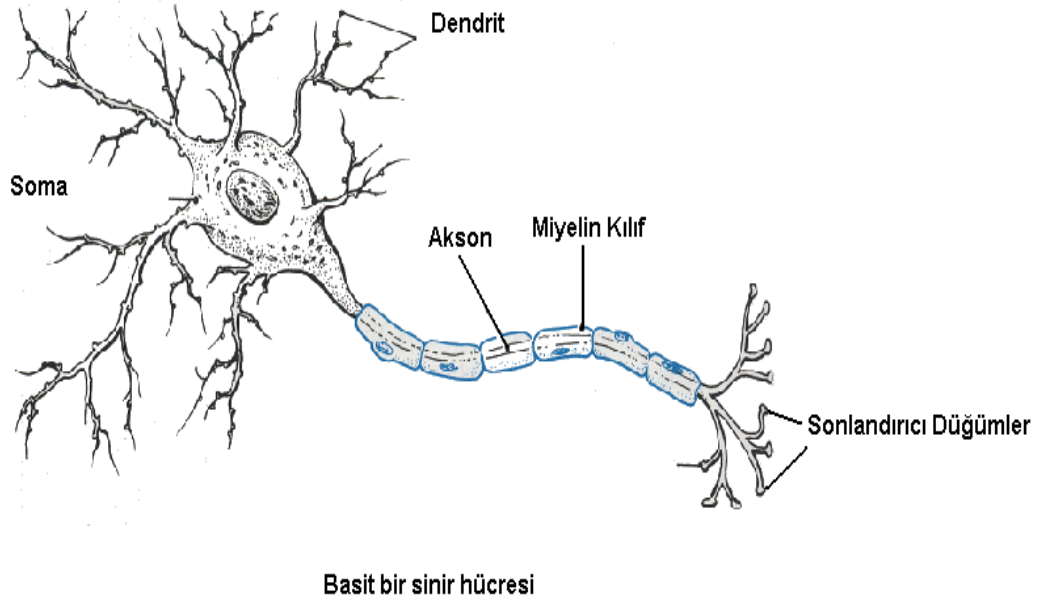
- 1974 : Geriye yayılım modelinin (çok katmanlı algılayıcının ilk çalışmalarının) geliştirilmesi.
- 1978 : Öğretmensiz öğrenmenin geliştirilmesi ART modelinin geliştirilmesi
- 1982 : Kohonen öğrenmesi ve SOM modelinin geliştirilmesi
- 1982 : Hopfield ağlarının geliştirilmesi
- 1982 : Çok katmanlı algılayıcıların geliştirilmesi
- 1984 : Boltzman makinesinin geliştirilmesi
- 1982 : Çok katmanlı algılayıcıların (genelleştirilmiş Delta öğrenme kuralı ile) öğrenmesinin geliştirilmesi
- 1988 : RTF modelinin geliştirilmesi
- 1988 : PNN modelinin geliştirilmesi
- 1991 : GRNN modelinin geliştirilmesi
- 1991'den günümüze sayısız çalışma ve uygulamalar geliştirilmiştir. Bunların listesini burada vermek neredeyse imkânsızdır.

2.3.2 Yapay sinir ağı hücresi

Biyolojik sinir ağının temel inşa bloğu olan basit bir sinir hücresi nöron olarak adlandırılır. Aşağıdaki şekil 2.7'de şematik diyagramı gösterilen tipik sinir hücresi üç ana bölümden oluşmaktadır. Soma olarak adlandırılan hücre gövdesi, akson ve dendritler bu ana bölümlerdir. Dendritler dendritik ağaç biçimindedir ve nöron gövdesi civarında uzun çalılar görünümündedirler. Dendritler üzerinden girişler alınır, soma tarafından girişler işlenir. Nörondaki sinyalleri taşıyan uzun bir sinirsel bağlantı halindeki akson ise, işlenen girişleri çıkışa aktarır. Akson dendrit bağlantısı ise sinaps olarak adlandırılır. Sinaps, nöronlar arasında elektro kimyasal bağlantıyı sağlamaktadır.

Bir insanın beyin korteksinde yaklaşık 10 milyar nöron ve yaklaşık 60 trilyon sinaps veya bağlantının bulunduğu tahmin edilmektedir [70]. Sonuçta beyin son derece verimli bir yapıdır. Özellikle beynin enerjik verimliliği, her saniyede her bir işlem için yaklaşık 10^{-16} joule'dur [70]. Bu değer bugünün en iyi bilgisayarlarında yaklaşık 10^{-6} joule'dur [70]. Beyin son derece karmaşık, doğrusal olmayan ve

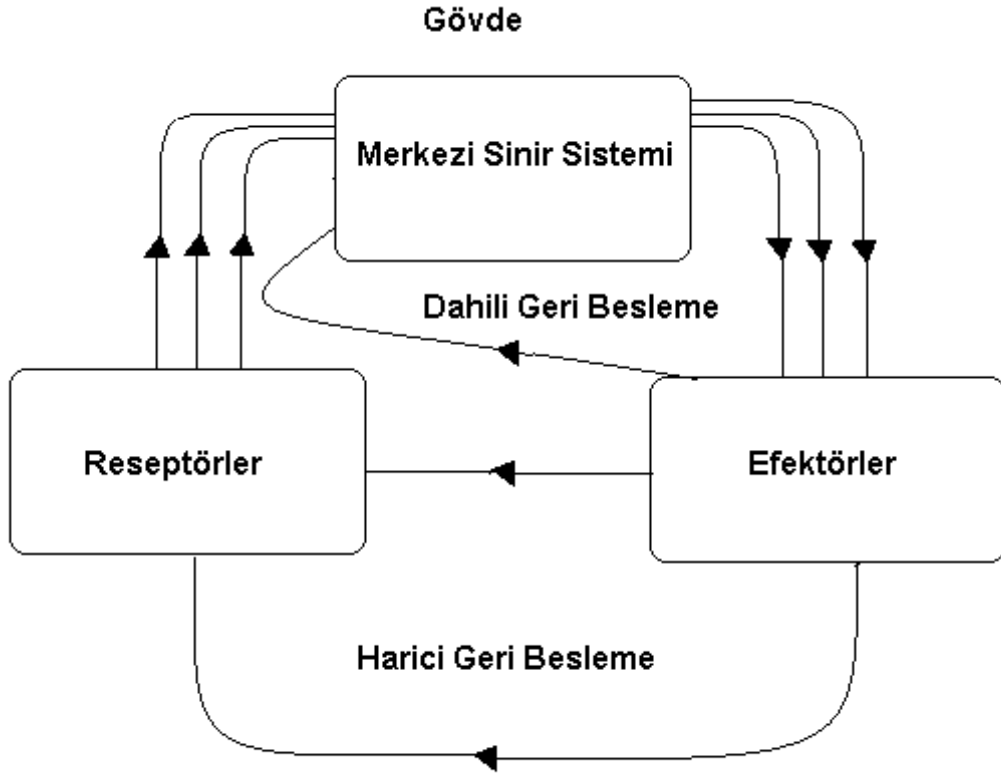
paralel bir bilgisayardır. Beynin nöronları organize etme yeteneği ve kesin hesaplamaları gerçekleştirmesi (görüntü tanıma, algılama gibi) bugünün en hızlı sayısal bilgisayarlarından daha hızlıdır. Diğer taraftan bir sinir hücresinin tepki hızı günümüzün bilgisayarlarına göre oldukça yavaş olmakla birlikte duyuusal bilgileri son derecede hızlı değerlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneği nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilir.



Şekil 2.6 : Basit sinir hücresi [38]' den değiştirilmiştir.

Bir hipoteze göre nöronlar birbirleriyle elektriksel sinyaller aracılığıyla haberleşmektedir [71]. Ayrıca, nöronlar kimyasal bir ortamda çok yoğun beyinsel faaliyetleri yerine getirmektedirler. Böylece beyin, biyokimyasal işlemlerin gerçekleştiği son derece yoğun bir elektriksel ağ gibi düşünebilir. Çok büyük sinir ağı çok karmaşık ve ayrıntılı bir yapıyla birbirine bağlıdır. Ağa giriş duyarlı algılayıcılar (reseptörler) ile sağlanmaktadır. Reseptörler uyarıyı gövdeye götürmektedirler. Uyarım elektriksel sinyaller biçimindedir. Nöron ağının içine bilgi taşınması ve merkezi sinir sisteminde bilginin işlenmesi sonucu efektörler kontrol edilmektedir. Bundan sonra insan cevabını çeşitli eylemler şeklinde vermektedir.

Yukarıda belirtildiği gibi sinir sisteminde bilgi akışı üç ana kısımda oluşmaktadır: Bunlar reseptörler, sinir ağı ve efektörlerdir.




Şekil 2.7. Sinir sisteminde bilgi akışı [72]'den değiştirilmiştir

Şekil 2.8'de görüldüğü gibi bilgi işlenmekte, değerlendirilmekte ve merkezi sinir sisteminde depolanan bilgiyle karşılaştırılmaktadır. Gerekli olduğunda komutlar merkezi sinir sisteminde üretilir ve motor organlara iletilir. Motor organlar eylemi doğrulayan geri beslemeli bağlantılarla merkezi sinir sistemini yönetmekte ve denetlemektedir. İç ve dış geri beslemeli kontrolün ikisi de komutlarla gerçekleştirilir. Görüldüğü gibi tüm sinir sisteminin yapısı kapalı-çevrim bir kontrol sistemini andırmaktadır.

Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. En temel nöron modeli şekil 2.9'da görülmektedir. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler (girişler), ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar

bulunmaktadır. Dış ortamdaki alınan veri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirlemektedir. Toplam fonksiyonu ise net girişi hesaplamaktadır. Net giriş, girişlerle bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışını hesaplar ve bu işlem aynı zamanda nöron çıkışını vermektedir. Genelde aktivasyon fonksiyonu doğrusal olmayan (nonlinear) bir fonksiyondur.



Şekil 2.8: Basit yapay sinir ağı modeli [39]'dan değiştirilmiştir.

Şekil 2.9'da görülen b bir sabittir. Bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılmaktadır. Nöronun matematiksel modeli şöyledir.

$$\text{Çıkış, } o = f(W \cdot X + b) \quad (2.11)$$

Şeklinde nöron çıkışı hesaplanır. Buradaki W ağırlıklar matrisi, X ise girişler matrisidir. n giriş sayısı olmak üzere denklem 2.12'de ki gibi yazılabilir;

$$W = w_1, w_2, w_3, \dots, w_n \quad (2.12)$$

$$X = x_1, x_2, x_3, \dots, x_n \quad (2.13)$$

Denklem 2.13 biçiminde yazılabilir. Formüle edilirse denklem 2.14 ve denklem 2.15 elde edilmektedir;


$$\text{net} = \sum_{i=1}^n w_i x_i + b \quad \text{ve} \quad o = f(\text{net}) \quad (2.14)$$

$$o = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad \text{şeklinde de yazılabilir.} \quad (2.15)$$

Denklem 2.15'de görülen f aktivasyon fonksiyonudur. Genelde nonlineer olan aktivasyon fonksiyonunun çeşitli tipleri bulunmaktadır [73].


2.3.3 Aktivasyon fonksiyonları

Şekil 2.10'da eşik aktivasyon fonksiyonunun grafiği görülmektedir. Eşik aktivasyon fonksiyonu, eğer net değeri sıfırdan küçükse sıfır, sıfırdan daha büyük bir değer ise net çıkışında +1 değerini vermektedir. Eşik aktivasyon fonksiyonunun -1 ile +1 arasında değişeni ise signum aktivasyon fonksiyonu olarak adlandırılmaktadır. Signum aktivasyon fonksiyonu, net giriş değeri sıfırdan büyükse +1, sıfırdan küçükse -1, sıfıra eşitse sıfır değerini vermektedir.



Şekil 2.9 Eşik aktivasyon fonksiyonu [74]'den değiştirilmiştir.


Aşağıdaki şekil 2.11'de doğrusal aktivasyon fonksiyonu görülmektedir. Lineer aktivasyon fonksiyonunun çıkışı girişine eşittir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun lineer aktivasyon fonksiyonu olabildiğine dikkat edilmelidir. Denklem 2.16'da matematiksel eşitliği görülmektedir.



Şekil 2.10. Doğrusal aktivasyon fonksiyonu [74]'den değiştirilmiştir

$$f(x) = x \text{ şeklinde ifade edilir.} \quad (2.16)$$

Şekil 2.12.'de logaritma sigmoid transfer fonksiyonu görülmektedir. Lojistik fonksiyon olarak da adlandırılmaktadır. Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmektedir ve böylece daha sonraki bölümlerde görülecek olan geri yayılım ağlarda kullanmak mümkün olabilmektedir.



Şekil 2.11. Logaritma Sigmoid aktivasyon fonksiyonu [74]'den değiştirilmiştir.

Lojistik fonksiyonu denklem 2.17’de ki gibidir,

$$f(x) = \text{lojistik}(x) = \frac{1}{1+\exp(-\beta x)} \quad (2.17)$$


şeklinde ifade edilir. Buradaki β eğim sabiti olup genelde bir olarak seçilmektedir. Diğer bir aktivasyon fonksiyonu olan hiperbolik tanjant aktivasyon fonksiyonu da lineer olmayan türevi alınabilir bir fonksiyondur. +1 ile -1 arasında çıkış değerleri üreten bu fonksiyon lojistik fonksiyona benzemektedir. Transfer fonksiyonu denklem 2.18’de görüldüğü gibidir.

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.18)$$

Bu aktivasyon fonksiyonlarından başka fonksiyonlar da bulunmaktadır. Yapay sinir ağında hangi aktivasyon fonksiyonunun kullanılacağı probleme bağlı olarak değişmektedir. Yukarıda verilen fonksiyonlar en genel aktivasyon fonksiyonlarıdır.

2.3.4 YSA modelleri

En basit ve en genel YSA tek yönlü sinyal akışını kullanmaktadırlar. YSA modelleri temel olarak iki grupta toplanmaktadır [75]. Bunlar İleri beslemeli YSA ve geri beslemeli YSA şeklindedir. İleri beslemeli YSA’nda gecikmeler yoktur, işlem girişlerden çıkışlara doğru ilerlemektedir. Çıkış değerleri öğreticiden alınan istenen çıkış değeriyle karşılaştırılarak bir hata sinyali elde edilerek ağ ağırlıkları güncellenmektedir [76]. İleri beslemeli YSA yapısının tipik şekli şekil 2.13’de betimlenmiştir.

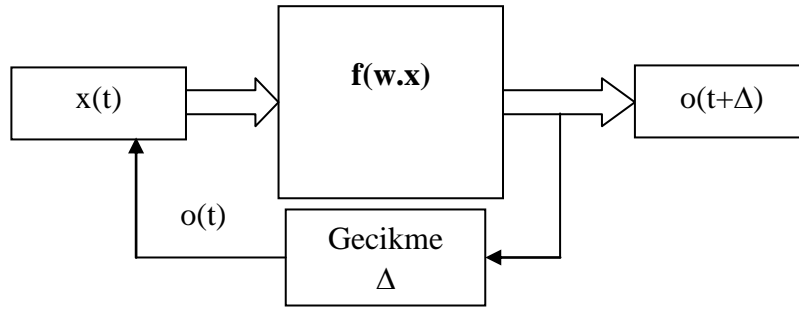


Şekil 2.12. İleri beslemeli yapı

Geri beslemeli YSA'nda ise tıpkı kontrol uygulamalarında olduğu gibi gecikmeler söz konusudur. Geri beslemeli nöral ağ, çıkışlar girişlere bağlanarak ileri beslemeli bir ağdan elde edilmektedir. Ağın t anındaki çıkışı $o(t)$ ise, $t + \Delta$ anındaki çıkışı ise $o(t + \Delta)$ 'dir. Buradaki Δ sabiti sembolik anlamda gecikme süresidir. İleri beslemeli yapay sinir ağları notasyonu kullanılarak $o(t + \Delta)$ denklem 2.19'da ki gibi yazılabilir.

$$o(t + \Delta) = f [W.o(t)] \quad (2.19)$$

Denklem 2.19'da ki eşitlik şekil 2.14'de ifade edilmiştir. Dikkat edilmesi gereken nokta başlangıç anında $x(t)$ 'ye ihtiyaç duyulmasıdır. Başlangıç anında $o(0) = x(0)$ 'dir.



Şekil 2.13. Geri beslemeli yapı.

2.3.5 YSA'nın eğitilmesi

İnsan beyni doğumdan sonraki gelişme sürecinde çevresinden duyu organlarıyla algıladığı davranışları yorumlamakta ve bu bilgileri diğer davranışlarında kullanmaktadır [53;70]. Yaşadıkça beyin gelişip ve tecrübelenmektedir. Artık olaylar karşısında nasıl tepki göstereceğini çoğu zaman bilmektedir. Fakat hiç karşılaşmadığı bir olay karşısında yine de tecrübesiz kalabilir.

YSA'nın öğrenme sürecinde de, tıpkı dış ortamdan gözle veya vücudun diğer organlarıyla uyarıların alınması gibi dış ortamdan girişler alınır, bu girişlerin beyin merkezine iletilerek burada değerlendirilip tepki verilmesi gibi yapay sinir ağında da aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı üretilir [70].

Bu çıkış yine tecrübeyle verilen çıkışla karşılaştırılarak hata bulunmaktadır. Çeşitli öğrenme algoritmalarıyla hata azaltılıp gerçek çıkışa yaklaşılmaya çalışılmaktadır. Bu çalışma süresince yenilenen yapay sinir ağının ağırlıklarıdır. Ağırlıklar her bir çevrimde yenilenerek amaca ulaşılmaya çalışılır. Amaca ulaşmanın veya yaklaşmanın ölçüsü de yine dışarıdan verilen bir değerdir. Eğer yapay sinir ağı verilen giriş-çıkış çiftleriyle amaca ulaşmış ise ağırlık değerleri saklanmaktadır. Ağırlıkların sürekli yenilenip istenilen sonuca ulaşılan kadar geçen zamana öğrenme adı verilir. Yapay sinir ağı öğrendikten sonra daha önce verilmeyen girişler verilir, sinir ağı çıkışıyla gerçek çıkışı yaklaşımı incelenmektedir. Eğer yeni verilen örneklere de doğru yaklaşıyorsa sinir ağı işi öğrenmiş demektir. Sinir ağına verilen örnek sayısı optimum değerden fazla ise sinir ağı işi öğrenmemiş ezberlemiştir. Genelde eldeki örneklerin yüzde sekseni ağa verilip ağ eğitilir, daha sonra geri kalan yüzde yirmilik kısım verilip ağın davranışı incelenir diğer bir deyişle ağ böylece test edilir [77].

2.3.6 YSA'nda öğrenme algoritmaları

1990'lı yıllardan bugüne gelinceye kadar birçok öğrenme algoritması geliştirilmiştir. Öğrenme algoritmaları temelde üç grupta toplanmaktadır. Eğitici öğrenme, eğitici öğrenme ve takviyeli öğrenme algoritmalarıdır [70;78].

Eğitici (supervised) öğrenmede, her bir örnekleme zamanında giriş uygulandığında sistemin arzu edilen cevabı y , eğitici tarafından sağlanmaktadır. Arzu edilen çıkış y ile sinir ağı çıkışı o arasındaki fark hata ölçüsüdür ve ağ parametrelerini güncellemekte kullanılmaktadır. Ağırlıkların güncellenmesi süresince eğitici ödüllendirme-cezalendirme şemasını ağa uygulayarak hatayı azaltmaktadır. Bu öğrenme modelinde giriş ve çıkış örnekleri kümesi eğitim kümesi olarak adlandırılmaktadır [70;79].

Eğitici öğrenmede eğitici öğrenmedeki gibi arzu edilen y çıkışları bilinmemektedir. Bu yüzden kesin bir hata bilgisini ağın davranışını değiştirmekte kullanmak mümkün değildir.

Cevabın doğruluğu veya yanlışlığı hakkında bilgi sahibi olunmadığı için öğrenmede başarıya, girişlerin verdiği cevaplar gözlenerek ulaşılmaktadır. Aslında eğitici-siz öğrenme demek doğru değildir çünkü eğitici-siz öğrenme gerçekte mümkün değildir. Eğiticinin her öğrenme adımında dâhil olmamasına rağmen amaçları ayarlamaktadır [70;79].

Takviyeli öğrenmede, ağıın davranışının uygun olup olmadığını belirten bir öz yetenek bilgisine ihtiyaç duyulmaktadır. Bu bilgiye göre ağırlıklar ayarlanır. Gerçek zamanda öğrenme yöntemi olup deneme-yanılma esasına göre sinir ağı eğitilmektedir.

Birçok öğrenme algoritmasının bulunmasından dolayı bu bölümde sadece çalışmamızda kullanılan öğrenme algoritması olan Geri Yayılım Algoritması ilgili bilgi verilecektir.

Geri yayılım algoritması eğitici öğrenmede kullanılan en genel algoritmadır. Basit olması ve iyi bir öğrenme kapasitesine sahip olması birçok alanda uygulanmasını sağlamıştır.


2.3.6.1 Geri yayılım öğrenme algoritması

Geri yayılım algoritması, sinir ağıının eğitici sınıfına giren genel bir algoritmadır [80]. Daha öncede belirtildiği gibi girişlerle çıkışlar arasındaki hata sinyali bulunarak, ağırlıklar bu hata sinyaliyle güncellenmektedir. Hata, yani $e(k)$, arzu edilen çıkış (gerçek çıkış - $y(k)$) ile sinir ağıının çıkışı ($o(k)$) arasındaki farktır [81]. Bu durum denklem 2.20'de gösterilmektedir.

$$e(k) = y(k) - o(k) \quad (2.20)$$

Aşağıdaki şekilde birçok sinir hücresinin birbirine bağlandığı ileri yönlü çok katmanlı bir yapay sinir ağı görülmektedir.

Giriş katmanı ile çıkış katmanı arasındaki katman veya katmanlar gizli katman olarak adlandırılmaktadır. Sinir ağlarında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç nöron olacağı bugüne kadar belirlenememiştir (Şekil 2.15). Probleme göre değişen bu nitelikler deneme-yanılma yoluyla bulunmaktadır.



Şekil 2.14 İleri beslemeli çok katmanlı sinir ağı [48]'den değiştirilmiştir.

Şekildeki çok katmanlı ağı düşünersek [82;83];

$k+1$. katmanda i . birime net giriş denklem 2.21'de ki gibi görülmektedir;

$$n^{k+1}(i) = \sum_{j=1}^{S_k} w^{k+1}(i,j)o^k(j) + b^{k+1}(i) \quad (2.21)$$

Ayrıca birim i 'nin çıkışı denklem 2.22'de ki gibi olacaktır.

$$o^{k+1}(i) = f^{k+1}(n^{k+1}(i)) \quad (2.22)$$

M katmanlı bir ağı, matris biçiminde ifade edilirse denklem 2.23'de ki eşitlik ortaya çıkmaktadır;

$$o^{k+1} = f^{k+1}(W^{k+1}o^k + b^{k+1}) \quad (2.23)$$

Ağın temel görevi giriş-çıkış çiftleri arasındaki ilişkiyi öğrenmektir.

$$k = 0, 1, \dots, M - 1 \quad \{(x_1, y_1), (x_2, y_2), \dots, (x_Q, y_Q)\} \quad (2.24)$$

Ağın performansı ise denklem 2.25'de görüldüğü gibidir;

$$E = \frac{1}{2} \sum_{q=1}^Q (y_q - o_q^M)^T (y_q - o_q^M) = \frac{1}{2} \sum_{q=1}^Q e_q^T e_q \quad (2.25)$$

Buradaki o_q^M , q. giriş (x_q) olduğunda ağın çıkışıdır, $e_q = y_q - o_q^M$ ise q. girişin hatasıdır. Standart geri yayılım algoritması için yaklaşık adım düşümü algoritmasını kullanır. Performans indeksiyle şöyle yaklaşılır;

$$E = \frac{1}{2} e_q^T e_q \quad (2.26)$$

Denklem 2.26'da toplam karelerin toplamı, tek giriş-çıkış çifti için karesel hatayla yer değiştirilmektedir. Yaklaşık adım (eğim) düşümü algoritması denklem 2.27 ve 2.28'de ki gibi oluşmaktadır.

$$\Delta w^k(i, j) = \alpha \frac{\partial E}{\partial w^k(i, j)} \quad (2.27)$$

$$\Delta b^k(i) = -\alpha \frac{\partial E}{\partial b^k(i)} \quad (2.28)$$

burada α öğrenme oranıdır ve şöyle tanımlanır;

$$\delta^k(i) \equiv \frac{\partial E}{\partial n^k(i)} \quad (2.29)$$

Performans indeksinin duyarlılığı k. katmanda i. birimin net girişinde değiştirilmektedir. Şimdi denklem 2.21, 2.26 ve 2.29 kullanılarak aşağıdaki denklemler elde edilir;

$$\frac{\partial E}{\partial w^k(i, j)} = \frac{\partial E}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial w^k(i, j)} = \delta^k(i) o^{k-1}(j) \quad (2.30)$$

$$\frac{\partial E}{\partial b^k(i)} = \frac{\partial E}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial b^k(i)} = \delta^k(i) \quad (2.31)$$

Hassaslık yeterliği aşağıdaki yinelemeli ilişkiyle de gösterilebilir.

$$\delta^k(i) = F^k(n^k)W^{k+1}\delta^{k+1} \quad (2.32)$$

burada;

$$\begin{bmatrix} f^k(n^k(1)) & 0 & \dots & 0 \\ 0 & f^k(n^k(2)) & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & f^k(n^k(Sk)) \end{bmatrix} \quad (2.33)$$

ve

$$f^k(n) = \frac{df^k(n)}{dn} \quad (2.34)$$


$$\delta^M = -F^M(n^M)(y_q - o_q) \quad (2.35)$$

Tüm öğrenme algoritmalarında şu adımlar izlenmektedir. İlk önce denklem 2.23 ve 2.24 kullanılarak giriş ileri yönde yayılır. Daha sonra denklem 2.35 ve 2.32 kullanılarak geri yayılmakta ve son olarak ağırlıklar ve denge denklem 2.27, 2.28, 2.30 ve 2.31'de ki gibi kullanılarak güncellenmektedir [70;81;83].

2.3.7 Matlab'da yapay sinir ağırları fonksiyonları

Bu bölümde MATLAB 7.0 Neural Network Toolbox' ta çok katmanlı ileri beslemeli geri bildirim algoritması için kullanılan fonksiyonlar anlatılacaktır. Bu fonksiyonlar ağların eğitilmesi için kullanılmaktadır.

Burada anlatılacak olan üç transfer fonksiyonu geri bildirimde en çok kullanılan transfer fonksiyonlarıdır. Aşağıda X girişli nöronun temel grafik gösterimi bulunmaktadır. Her giriş uygun bir w (ağırlık) değeri ile ağırlıklandırılmıştır. Ağırlıklandırılmış girişler ile önyargı formlarının toplamı transfer fonksiyonu f 'nin girişini oluşturmaktadır. Nöronların çıkışlarını oluşturmak için her hangi bir diferansiyel transfer fonksiyonu kullanılabilir. Şekil 2.16'da x girişli bir nöronun temel grafik gösterimi görülmektedir




Şekil 2.15: X girişli bir nöronun temel grafik gösterimi [48]'den değiştirilmiştir.

2.3.7.1 Logsig fonksiyonu

Log-sigmoid fonksiyonu çok katmalı ağlarda sıkça kullanılmaktadır. Nöron girişleri negatiften pozitive giderken Logsig fonksiyonu 0 ile 1 arasında çıkış üretir. Şekil 2.12 deki gibi fonksiyonu gösterilmektedir [84].

2.3.7.2 Tansig fonksiyonu

Çok katmanlı ağlarda kullanılan diğer bir transfer fonksiyonu tan-sigmoid fonksiyonudur. MATLAB yapay sinir ağları alet kutusunda tansig fonksiyonu olarak kullanılmaktadır [84].



Şekil 2.16: Tan-sigmoid transfer fonksiyonu [74]'den değiştirilmiştir.

2.3.7.3 Purelin fonksiyonu

Diğer bir transfer fonksiyonu da purelin fonksiyonudur. Nadir olarak geri bildirimli ağlarda lineer transfer fonksiyonu olan purelin kullanılmaktadır [84]. Şekil 2.11'de purelin fonksiyonu gösterilmiştir.

Eğer çok katmanlı ağların son katmanındaki nöronlar sigmoid nöronlar ise ağın çıkışları küçük bir aralıkla sınırlıdır. Eğer lineer çıkış nöronları kullanıldıysa ağ çıkışları herhangi bir değer alabilir.

Geri bildirimde kullanılan herhangi bir transfer fonksiyonunun türevinin hesaplanabilmesi önemlidir. Yukarıdaki transfer fonksiyonlarının (tansig, logsig, purelin) türevleri dtansig, dlogsig, dpurelin dir. Transfer fonksiyonunun türevini bulmak için transfer fonksiyonu string 'deriv' ile çağırılır.

2.3.8 Bir Ağ Oluşturmak (newff)

İleri beslemeli ağı eğitmek için ilk aşama bir ağ objesi oluşturmaktır. newff fonksiyonu ileri beslemeli ağ oluşturur [85]. 4 girişe ihtiyaç duyar ve ağ objesine dönüşür. Birinci giriş Rx2 matrisidir. Bu matris giriş vektöründeki her R elemanının minimum ve maksimum değeridir [84;85].

İkinci giriş her katmanın boyutunu içeren bir dizidir. Üçüncü giriş her katmanda kullanılacak olan transfer fonksiyonlarının adlarını içeren bir küme dizisidir. Son giriş ise kullanılacak eğitim fonksiyonunun adını içermektedir [85].

```
net= newff ( [-1 2 ; 0 5],[3,1],{'tansig','purelin'},'traingd');
```

Yukarıdaki komut, bir ağ objesi üretmekte ve ağırlıklarını belirlemektedir. Böylelikle ağ eğitime hazır hale getirilmiştir.

2.3.9 Ağın Eğitimi

Ağın ağırlıkları ve tahminleri bir kere belirlendiği zaman ağ eğitime hazırdır. Ağ fonksiyon yaklaşımı (lineer olmayan gerileme) model birliği ve model sınıflandırması için eğitilebilir. Ağ eğitim işlemi, doğru ağ davranışı, ağ girişi p ve uzak çıkış t den oluşan birkaç örnek kümeyle ihtiyaç duymaktadır. Eğitim esnasında ağ performansının iyi olması için ağırlık ve tahminler otomatik olarak net.performFcn fonksiyonu tarafından ayarlanır. İleri beslemeli ağlar için sabit performans fonksiyonu mse'dir (ortalama hata karesidir). Ağ çıkışı ile uzak çıkış arasındaki hatanın karesinin ortalamasıdır [80;86]

Bu bölümde ileri beslemeli ağlar için birçok farklı eğitim algoritmasından bahsedilmektedir. Bütün bu algoritmalar ağırlıkların ayarlanması ve performansın minimuma indirilmesi için performans fonksiyonunun gradyanını kullanmaktadır. Gradyant geri bildirim tekniği kullanılarak hesaplanmaktadır. Geri bildirim gerideki hesaplamaları ağa tekrar vermeyi içermektedir. Geri bildirim hesaplaması matematikteki zincir kuralı kullanılarak elde edilmektedir. Temel geri bildirimli eğitim algoritmasında ağırlıklar negatif gradyanlar yönünde hareket etmektedir.

2.3.10 Geri yayılım algoritması

Geri bildirim algoritmasında birçok değişken vardır. Geri bildirimli öğrenim algoritmasının en basit gösteriminde ağırlıklar ve tahminler performans

fonksiyonunun düzenli azaldığı (negatif gradyant) yönünde güncellenir.

$$x_{K+1} = x_K - \alpha_K g_K$$

x_K = şu anki ağırlık ve tahminler

g_K = şu anki gradyant

α_K = öğrenme derecesi

Azalan gradyant algoritmasının gerçekleşmesinin iki farklı yolu bulunmaktadır; Bunlar artırım modu ve takım modudur. Artırım modunda her girişin ağa uygulanmasında hesaplanmakta ve ağırlıklar güncellenmektedir. Takım modunda bütün girişler ağa ağırlıklar güncellenmeden uygulanmaktadır.

2.3.11 Takım eğitimi (train)

Bu moda ağın ağırlıkları ve tahminleri; bütün eğitim seti ağa uygulandıktan sonra güncellenir. Ağırlık ve tahminlerdeki değişimi elde etmek için her eğitim örneğinde hesaplanan gradyantlar toplanır [80].

2.3.12 Takım gradyant azalışı (traingd)

Takım keskin azalış eğitim fonksiyonu traingd'dir. Ağırlıklar ve tahminler performans fonksiyonunun negatif gradyant yönünde güncellenmektedir. Eğer bir ağ takım keskin azalışı kullanarak eğitilmek istenirse, ağ trainFcn'yi traingd'ye ayarlamak ve train fonksiyonunu çağırmak gerekmektedir. Verilen bir ağın sadece bir eğitim fonksiyonu bulunmaktadır [80].

Traingd'nin 7 tane eğitim parametresi vardır (epochs, show, goal, time, min_grad, max_fail, lr= öğrenme katsayısı). Ağırlık ve tahminlerdeki değişimi hesaplamak için lr, negatif gradyantla çarpılır. Öğrenme katsayısı ne kadar büyükse aralık o kadar büyük olmaktadır. Eğer öğrenme katsayısı çok aşırı büyük yapılırsa algoritma güvenilir hale gelmektedir. Eğer öğrenme katsayısı çok aşırı küçük ayarlanırsa algoritmanın çalışması çok uzun sürmektedir.

Algoritmanın show iterasyonunda eğitim durumu gösterilmektedir. Diğer parametreler eğitim bittiğinde elde edilmektedir. Eğitim, iterasyon sayısının epochs'u aşmasıyla; performans fonksiyonunun goal'un altına düşmesiyle, gradyant değerinin min_grad'tan aşağı düşmesiyle veya eğitim zamanının time'dan uzun olmasıyla durmaktadır. max_fail ise erken durdurma tekniğidir.

Aşağıdaki kod p girişli t hedefli eğitim seti oluşturmaktadır. Takım eğitiminde bütün giriş vektörleri bir matrisin içinde yer almaktadır.

```
p = [ -1 -1 2 2; 0 5 0 5];
```

```
t = [-1 -1 1 1];
```

Daha sonra ileri beslemeli ağ oluşturulmaktadır. Minmax fonksiyonu ağdaki girişlerin değer aralığını tespit etmek için kullanılmaktadır.

```
net = newff (minmax(p), [3,1],{'tansig', 'purelin'},'traingd');
```

Bu noktada verilen bazı eğitim parametreleri yenilenmek istenirse aşağıdaki komutlar kullanılmaktadır.

```
net.trainParam.show=50;
```

```
net.trainParam.ir=0.05;
```

```
net.trainParam.epochs=300;
```

```
net.trainParam.goal = 1e-5;
```

Eğer verilen parametreler kullanılmak istenirse yukarıdaki komutlar önemli değildir.

2.3.13 Momentumlu takım gradyant azalışı (traingdm)

Traingd'ye göre daha hızlı sonuca ulaşmaktadır. Momentumlu keskin azalışı bulunmaktadır [80;86]. Momentum, ağınlık lokal gradyantlarının dışında komşu hata yüzeylerindeki cevap vermesini sağlamaktadır.

Alçak geçiren filtre gibi davranarak momentum ağı hata yüzeyindeki küçük değerleri görmezden gelmesini sağlamaktadır. Momentumsuz ağı yüzeysel yerel minimumda takılır. Momentumlu ağı böyle bir noktayı geçebilmektedir. Momentum, geri bildirimli öğrenmeye eklenebilir. Bu ekleme ağırlık değişimlerini son ağırlık değişiminin parçalarının toplamına eşit olarak yapılmaktadır. Yeni değişim geri bildirim kuralı ile teklif edilmektedir. İzin verilen son ağırlık değişiminin etkisinin değeri momentum sabiti ile elde edilmektedir. (mc). mc 0 ile 1 arasındadır.

mc=0 ise ağırlık değişimi gradyanta bağlıdır.

mc=1 ise ağırlık değişimi son ağırlık değişimine eşittir, gradyant göz önüne alınmamalıdır.

Gradyant, her eğitim örneğindeki hesaplanan gradyantlar toplanarak bulunur. Ağırlık ve tahminler bütün eğitim örnekleri yapıldıktan sonra güncellenir. Eğer verilen bir iterasyondaki yeni performans fonksiyonu bir önceki iterasyondaki performans fonksiyonunu önceden tanımlanan mx_perf-inc oranında aşarsa yeni ağırlık ve tahminler göz ardı edilir ve mc=0 yapılır.

Momentumlu gradyant azalışı takımı, eğitim fonksiyonu traingdm ile kullanılmaktadır. traingdm, traingd ile aynı basamakları kullanır. Sadece öğrenme parametreleri mc,lr ve max_perf_inc değerleri ayarlanır. Eğer eğitimden önce ağırlık ve tahminleri yeniden düzenlersek, elde edilen ortalama hata karesi, traingd kullanarak elde edilenden farklı olmaktadır. Eğer tekrar değerlerle oynanıp traingd ile fonksiyon eğitilirse çıkan sonuçlar çok daha farklı olacaktır. Ağırlıkların ve tahminlerin rast gele seçilmiş ilk değerleri algoritmanın performansını etkilemektedir. Eğer farklı algoritmaların performanslarını kıyaslamak istenirse birçok başlangıç ağırlık ve tahmin değerleri kümesi ile test edilmelidir [86]. Aşağıda bu algoritmayla ilgili komutlar verilmiştir.

```
p = 1-1 -1 2 2;0 505];
```

```
t = [-1 -1 1 1];
```

```
net=newff(rninmax(p),[3,IJ,{'tansig','pureiin'}], 'traingdm');
```

```
net.trainParam.show = 50;
```

```
net.trainParam.lr = 0.05;  
net.trainParam.inc = 0.9;  
net.trainParam.epochs = 300;  
net.trainParam.goal = 1e-5;
```

2.3.13.1 Değişken Öğrenim Katsayısı (traingd, traingdx)

Standart keskin azalışta öğrenme katsayısı öğrenme boyunca sabit bir değerdir. Algoritmanın performansı öğrenim katsayısı değişikliklerine oldukça duyarlıdır. Eğer öğrenim katsayısı çok yüksek ayarlanırsa algoritma salınım yapar ve kararlılığını kaybeder. Eğer çok küçük ayarlanırsa algoritma cevabı çok gecikir. Öğrenimden önce öğrenme katsayısının optimum değerini belirlemek zordur. Bununla birlikte optimum öğrenim katsayısı eğitim işlemi sırasında değişir.

Eğer öğrenme katsayısının eğitim işlemi sırasında değişmesine izin verilirse keskin azalış algoritmasının performansı gelişmektedir. Adaptasyonlu öğrenme katsayısı, öğrenmenin kararlı olmasını sağlarken aynı zamanda öğrenme basamağı genişliğini olabildiğince geniş tutmaktadır. Öğrenme katsayısı yerel hata yüzeyindeki kompleksliğe karşı sorumludur [80].

Adaptasyonlu öğrenme katsayısı, traingd ile kullanılan öğrenme prosedüründe bazı değişikliklere ihtiyaç duymaktadır. İlk olarak başlangıç ağı çıkışı ve hata hesaplanır. Her epoch'ta yeni ağırlıklar ve tahminler geçerli öğrenim katsayıları kullanılarak hesaplanır. Sonra çıkışlar ve hatalar hesaplanır.

Momentumlu biçimde ise, yeni hata eski hatayı max_perf_inc ile daha önceden tanımlanmış olan orandan daha fazla aşarsa yeni ağırlık ve tahminler dikkate alınmaz. Buna ek olarak öğrenme katsayısı düşürülür. Aksi takdirde yeni ağırlıklar korunur. Eğer yeni hata eski hatadan daha az ise öğrenme katsayısı yükseltilir.

Bu prosedür öğrenme katsayısını yükseltir. Fakat bu sadece ağı geniş hata yükselişleri olmadan öğrenebilmesi içindir.

Bundan dolayı bir lokal bölge için optimum öğrenme katsayısı elde edilir. Öğrenme katsayısı kararsız öğrenmeye sebep oluyorsa arttırılır. Öğrenme katsayısı hatadaki düşüşü garanti edecek kadar yüksek olduğu zaman kararlı öğrenme sağlanana kadar düşürülür.

3. YÖNTEMLER

Bu bölümde dismorfik hastalıkların görüntü analizi için kullanılan yöntemlerin ayrıntılarını içermektedir. İlk kısımda fotoğraf veri tabanının oluşturulması, ikinci kısımda elastik yüz demet grafiğinin kullanılması ve son kısımda ise kullanılan yapay sinir ağı modelleri ve kullanılan metotlar yer almaktadır.

3.1 Fotoğraf Veri Tabanının Oluşturulması


Çalışmadaki temel amaç down sendromlu çocukların öznitelik vektörleri çıkarılıp yapay sinir ağıları algoritmaları ile klinik ön tanısının yapılabilmesidir. Temel amacın gerçekleştirilmesi için down sendromlu çocukların ve normal çocukların öznitelik vektörlerine ihtiyaç vardır. Çalışmanın orijinalliği açısından analiz için kullanılan down sendromlu çocuk ve normal çocuk fotoğraflarının tamamı Türkiye Cumhuriyeti vatandaşı çocuklardan elde edilmiştir.

Veri tabanının oluşturulabilmesi için down sendromlu ve normal morfolojiye sahip çocuk fotoğraflarına ihtiyaç duyulmuştur. Veri tabanındaki fotoğraflar 5-6 yaş grup arasındaki down sendromlu ve normal morfolojiye sahip çocuk fotoğraflarıdır. Down Sendromlu çocukların 8 tanesi kız, 10 tanesi erkektir. Normal morfolojiye sahip çocukların 12 tanesi kız, 6 tanesi erkektir. Fotoğrafların hepsi ile bir veri tabanı oluşturulmuştur. Fotoğrafların seçimi "Sonuçlar" bölümünde anlatılmıştır.

3.2. Gabor Dalgacıkların Oluşumu

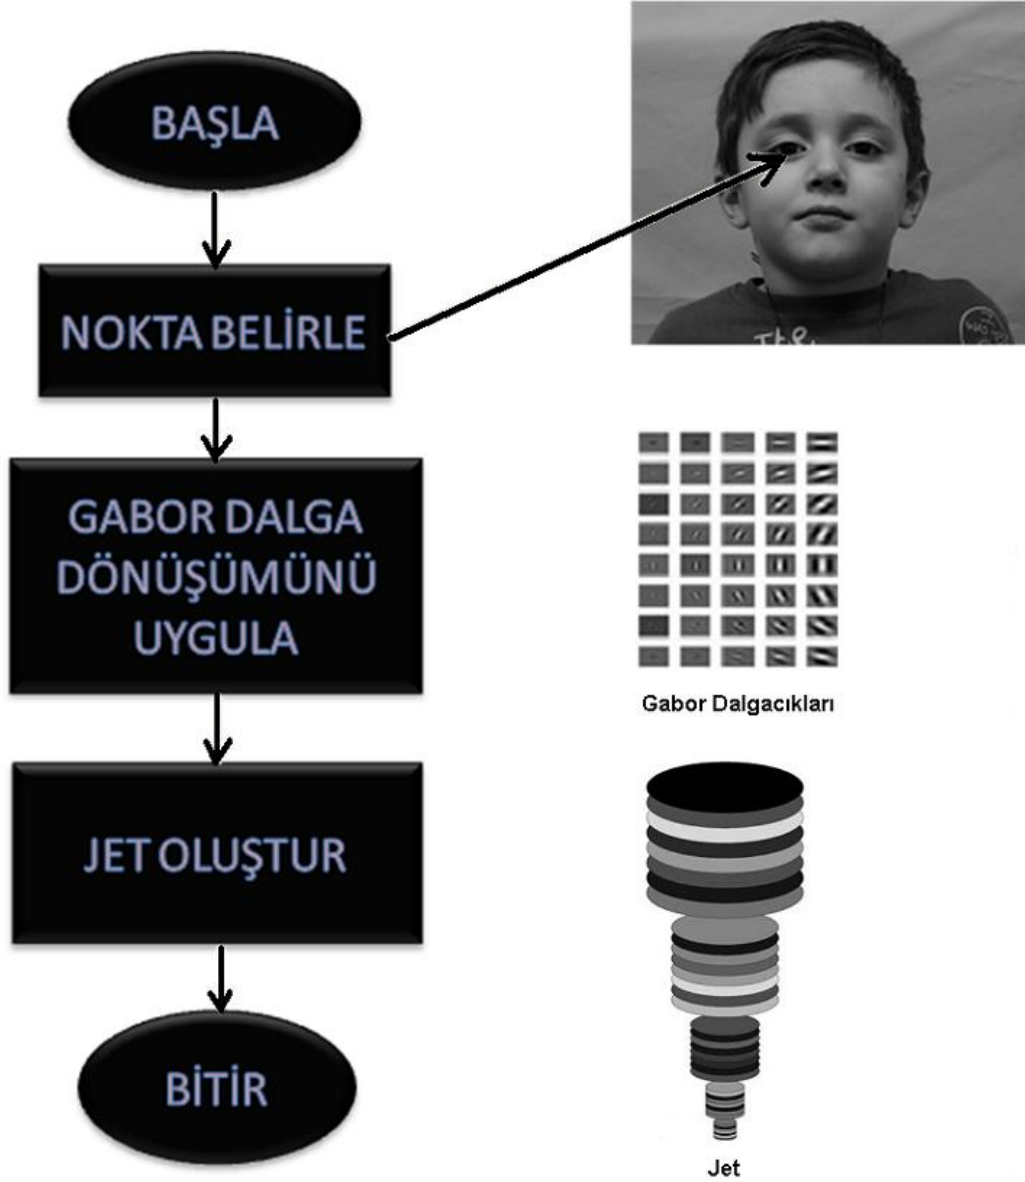
Bölüm 2.2.2.1'de anlatılan gabor dalgacıklarının formülüzasyonu sonucunda 40 adet gabor dalgacık matrisleri oluşturulmuştur. Matrislerin her biri bölüm 2.2.2.1'de de anlatıldığı gibi farklı frekans ve farklı yönelimdedirler. Matrisler ile istenilen noktanın (sağ göz noktası) konvolusyon işleminin sonucunda bir jet elde edilmektedir. Jetler ile yüz maskesinin çıkarılması işlemi her bir nokta ile elde etmiş olduğumuz 40 adet nokta konvolusyon işlemi gerçekleştirilir.

Daha sade bir şekilde anlatmak gerekirse seçilen noktaların gabor dalgacık matrisleri ile sırayla konvolusyon işlemi gerçekleştirilir ve çıkan sonuç jet olarak ifade edilir. Jetin oluşturulması için şekil 3.2’de bir akış şeması oluşturulmuştur. Sonuçta elde ettiğimiz jetler ile bir yüz grafik maskesi oluşturulmuş olur. Şekil 3.1’de farklı frekans ve farklı yönelimli gabor dalgacıkları görülmektedir.



Şekil 3.1: 5 frekans 8 farklı yönelimli gabor dalgacıkları

Şekil 3.2’de de görülebileceği gibi istenilen noktadan jetin oluşturulması için akış şeması gösterilmiştir. Akış şemasına göre imajda istenilen noktanın kordianatları belirtilir. Gabor dalga dönüşümü ile oluşturulan gabor dalgacıkları seçilen nokta ile konvolusyon işlemi uygulanır. Her bir dalgacığın konvol edilmesinin sonucunda seçilen nokta için bir adet jet oluşur. Daha öncede belirtildiği gibi bu akış şeması istenilen her bir nokta için uygulandığında şekil 2.5 de görülen yüz demet grafiği oluşturulur.



Şekil 3.2: Jet akış şeması

3.2 Yüz Üzerinde Nokta Tespiti

Yüz tanıma, bilgisayar mühendisliği veya görüntü işleme ile uğraşan birçok kişi için halen ilgi çekiciliğini korumaktadır. Geçmiş yirmi yıl içerisinde birçok yüz tanıma metodu, ortaya atılmıştır. Bu metotlar yarı otomatik algoritma ve tam otomatik algoritma olarak iki tipte sınıflandırılabilir.

Yarı otomatik algoritmalar sisteme verilen yüz hakkında önceden bilgi sahibidir. Örneğin gözün hangi koordinatlarda olduğunu bilmektedir.

Oysa tam otomatik algoritmalar ise yüz hakkında önceden bilgi sahibi değildirler. Fakat şimdiye kadar yapılan yüz tanıma çalışmalarının birçoğu, yarı otomatik algoritmalarıdır. Fakat günümüzde tam otomatik yüz algoritmaları ile yapılan çalışmalar ve tam otomatik yüz tanımaya olan ihtiyaç artmaktadır.

Elastik Demet Grafik Metodu (EDGM) tam otomatik yüz algoritmalarının en iyi algoritmalarından biri olarak kabul edilmektedir [87]. Bu yüzden EDGM'nin performansını artırmaya yönelik ek çalışmalar yapılmaktadır. Bu çalışmada EDGM'nin performansını artırmaya yönelik, geliştirilmiş İşaretleyici Model Eşleştirme Metodunda (IMEM) [88] kullanılan işaretleyici tespit metodu uygulanmıştır. Bu metot EBGM'deki eksiklikleri optimizasyon yaklaşımı kullanılarak tamamlamaktadır. Kısaca IMEM'nda bir yüz işaretleyici model tarafından temsil edilir (IM). İşaretleyici dağıtım modeli bir kaç eğitilmiş görüntü tarafından oluşturulur. En uygun işaretleyici modeli elde etmek için yeni bir IM uygun sınırlar içinde geometrik yapısını bozarak oluşturulur. Bir sonraki bölümde EDGM metodunun uygulanması ve bu metoda ilave edilen Noktacık Küme Optimizasyon (Particle Swarm Optimization) uygulanarak yeni bir algoritma olan IMMM [88] modeli anlatılacaktır.

3.2.1 EDGM ve IMEM Metotları

Elde edilen çocuk fotoğraflarının yüz grafiklerini çıkarmak için işaretleyici model eşleme metodu (IMEM) uygulanmıştır. Elastik Demet Grafik Eşleştirmenin amacı, yüzdeki anlamlı noktaları bulmaktır. Bunun için aşağıdaki denklem 3.1'de ki eşitlik uygulanır [87;89].

$$S_G(G^I, G^M) = \frac{1}{N} \sum_n S_a(J_n^I, J_n^M) \quad (3.1)$$

Böylece grafik olarak tanımlayan Yüz Demet Grafiği (YDG) ile benzerliği maksimize eden bir grafik çıkarılmıştır. Bundan sonraki işlemler sırasıyla aşağıdaki gibi anlatılabilir:

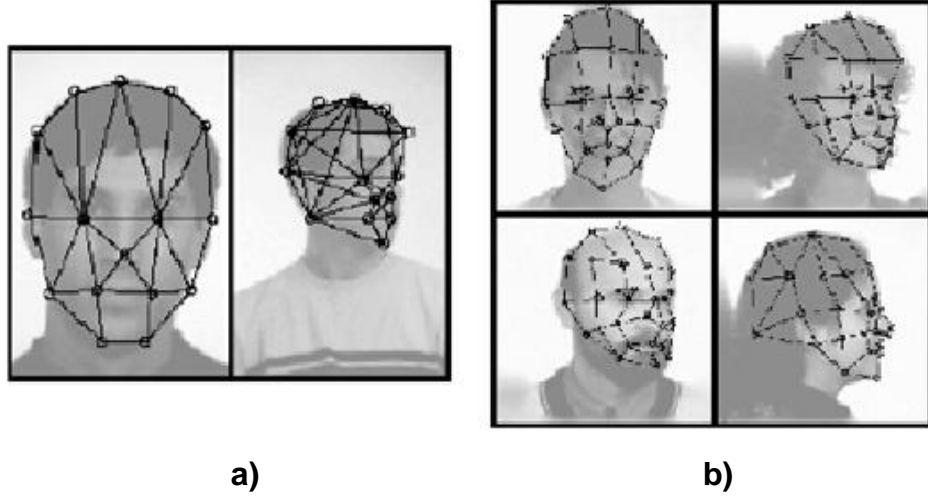
Adım 1: Yaklaşık yüz pozisyonu bulunur. Her bir yüz demet grafiği demeti içindeki jetlerin ortalama büyüklüklerini alarak bir ortalama grafik içinde YDG yoğunlaştırılır. Bunu bir maske model olarak kullanabiliriz $\lambda = \infty$ ve 4 piksellik bir aralığa sahip her bir kare kafes konumunda benzerliği değerlendirilir. Bu adımda, S_\emptyset yerine, safha olmaksızın benzerlik fonksiyonu S_α kullanılmıştır. 1 piksellik bir aralıkla en iyi uyum pozisyonu çevresinde tarama tekrarlanır. Son olarak, en iyi uyum pozisyon, sonraki adım için başlangıç noktası görevi görür.

Adım 2: Pozisyon ve büyüklük ayarlanır. Ortalama olmaksızın yüz demet grafiği kullanılır, pozisyon ve büyüklük bakımından değişikliğe uğrar. Adım 1'e bulunan pozisyondan çıkarılan dört farklı pozisyon ($\pm 3, \pm 3$) pikselleri kontrol edilir, ve her pozisyonda aynı merkez pozisyona sahip iki farklı büyüklük kontrol edilir. Bunun benzerlik üzerinde etkisi yoktur, çünkü vektörler \vec{x}_e^B buna uygun olarak dönüştürülürler. Her nokta için en iyi uyum jet seçilir ve bölüm 2.2.2.3 de anlatılan denklem (8) göre yerinden çıkarılması hesaplanır. Yerinden çıkarmalar, sekiz piksele kadar büyüklüğe sahip olabilirler. Daha sonra, yerinden çıkarmalar üzerindeki kare toplamını en az düzeye indirmek amacıyla ızgaralar yeniden ölçeklenirler ve yeniden yerleştirilirler. Sonraki adım için başlangıç noktası olarak sekiz varyasyonun en iyi şekli korunur.

Adım 3: Büyüklük tasfiye edilir ve özellik oranını bulunur. Adım 2'de tarif edilen şekilde benzer bir gevşeme süreci uygulanır fakat x ve y boyutları bağımsız olarak gevşetilir. Ayrıca odak 1'den 5'e kadar sırayla arttırılır.

Adım 4: Yerel çarpıtma. Sözde rasgele bir dizilimde, YDG'ye benzerliği daha fazla arttırmak için her bir bireysel görüntü boğumunun pozisyonu değişiklik gösterir. Adım 3'te elde edilen şekilde, \vec{x}_e^B vektörlerini kullanarak $\lambda = 2$ ayarını hesaba katarak metrik benzerlik hesaba katılır. Bu adımda, sadece tahmin edilen yerinden değiştirme vektörünün küçük olduğu pozisyonlar göz önüne alınır.

Sonuçta meydana gelen grafiğe görüntü grafiği adı verilir ve görüntünün bireysel yüzünün bir temsili olarak saklanır. Şekil 3.3'a ve b'de farklı pozlar için nesne uygulama ızgaraları görülmektedir.




Şekil 3.3 a) Yüzü bulmak için ızgaralar b) Yüzü tanımak için ızgaralar

Noktacıklar temsil eden yüz demeti grafiklerine karşı elastik grafiği eşleştirerek otomatik olarak yerleştirilirler. Yüzü güvenilir bir şekilde bulmak için dış çizgiler üzerinde birçok normalleştirme aşaması soldaki iki görüntü tarafından gösterilmektedir. Görülebilir ki genel olarak eşleştirme yüzdeki anlamlı noktaları oldukça doğru bir şekilde bulmaktadır. Fakat yanlış eşleştirmeler meydana gelmektedir. Örneğin, sakallı adam için. Çene doğru bir şekilde bulunamamıştır; en soldaki boğum ve alttaki boğum, kulağın sırasıyla üstünde ve altında yer almalıdır.

Elastik demet grafik eşleme [87] yönteminde genişçe dikdörtgenler insan yüzüne örtülerek yüz üzerindeki kritik noktaların işaretlenmesi sağlanır. İki boyutlu Gabor dalgacıklarının konvolüsyon setinin dikdörtgenler üzerindeki her noktada hesaplanmasıyla, yüz üzerinde işaretlenen kritik noktaları ifade eden özellik vektörü elde edilmiş olmaktadır. Ardından grafik eşleme yöntemlerinden biri kullanılarak grafik şablonlarının karşılaştırılması yapılır.

Elastik demet grafik eşleme yönteminde en önemli adımlardan biri, yüz üzerindeki kritik noktaların dikdörtgenler üzerine tam ve doğru olarak bulmaktır. Bunun için

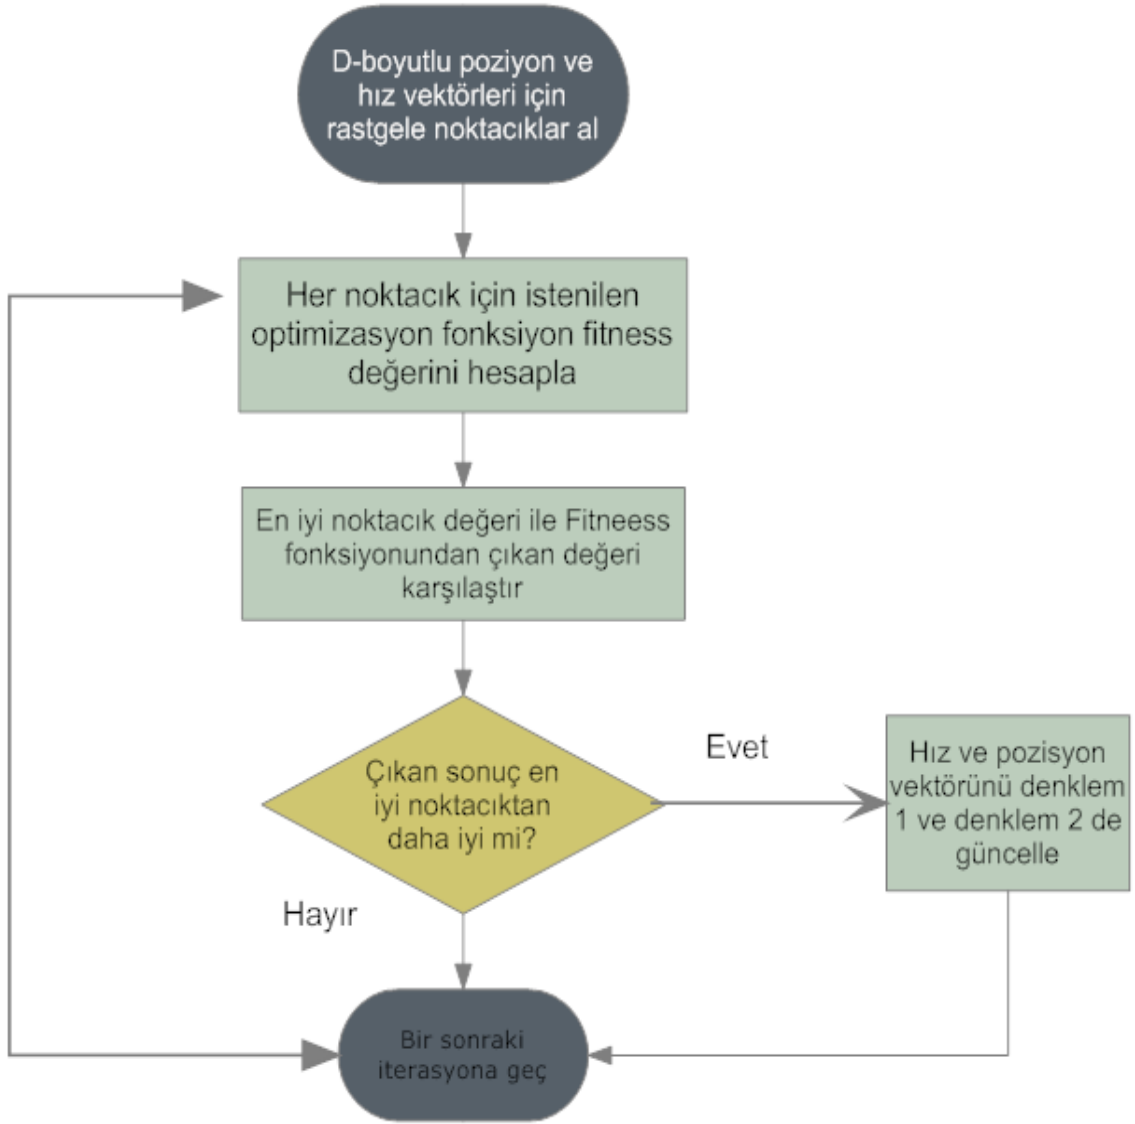
EDGM'de bir grup yüz modelinden yüzün genel demetsel görünümü çıkartılır ve daha sonra istenen resim ile bu demet eşlenir. Şekil 3.4'de EDG örneği görülmektedir.



Şekil 3.4: Elastik demet grafik örneği [87]'den değiştirilmiştir

3.2.2 Noktacık küme optimizasyonu (NKO)

NKO [87], matematiksel bir hesaplama tekniğidir ve karmaşık verilerin hesaplanmasında en iyi optimizasyon yöntemidir. NKO, bireysel noktacıklar arasındaki değişimi iyi bir şekilde verir [88]. Her nokta, bulunduğu koordinattan önceki en iyi konumuna doğru koordinatını ayarlar. Şekil 3.5'de noktacık küme optimizasyonunun akış diyagramı görülmektedir.



Şekil 3.5: NKO akış diyagramı

Örneğin D boyutlu bir uzay vektörü ele alınırsa; i. noktacığın d-boyutlu bir vektörü $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})^T$, noktacığın pozisyon değişimini ise d-boyutlu $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})^T$ olarak tanımlanabilir.

Noktacığın bir önceki pozisyonu $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})^T$ olarak gösterilirse; tekrarlama sayısını ifade etmesi için g' ye , kümedeki en iyi taneciğın indeksi verilir ve sonra taneciğın hızını ve noktacığın pozisyonunu hesaplamak için denklem 3.2'de ki eşitlik kullanılabilir [91;92].

$$v_{id}^{n+1} = X [\omega v_{id}^n + c_1 r_1^n (p_{id}^n - x_{id}^n) + c_2 r_2^n (p_{gd}^n - x_{id}^n)] \quad (3.2)$$

$$x_{id}^{n+1} = x_{id}^n + v_{id}^{n+1} \quad (3.3)$$

Bu denklemde $d = 1, 2, \dots, D$ 'ye kadar ve $i = 1, 2, \dots, N$ 'ye kadardır. N noktacık sayısı, c_1 ve c_2 ivme sabitleri, r_1 ve r_2 , 0 ile 1 arasındaki rasgele sayılar, $n=1, 2, \dots$ tekrarlama sayısı, ω eylemsizlik ağırlığı [87] ve son olarak X de sıkışma katsayısı olarak alınmamaktadır [89]. NKO'yu yerine getirmek için şekil 3.3 akış diyagramı takip edilir.

Y.Shi ve arkadaşları [91], Ratnaweera ve arkadaşları [92] ve S. Patchararungruang ve arkadaşları [93] NKO metodu için büyük iterasyonlu çalışmalar gerçekleştirmişlerdir. Bu çalışmalar büyük iterasyonlar için iyi sonuçlar vermektedir. Fakat tarafımızdan yürütülen çalışmada buna ihtiyaç olmadığından dolayı daha önce belirtilen şekil 3.3'de ki akış diyagramı kullanılmıştır.

3.2.3 İşaretleyici bulma

Bu bölümde işaretleyicinin yerlerinin bulunması anlatılacaktır. İşaretleyici bulma işleminde x-y eksenlerinde işaretleyicilere farklı değerler atanır. NKO algoritması kullanırken toplam her bir işaretleyicinin boyutları aynı olacak şekilde ayarlanmıştır ve 8 adet noktacık için hesaplanmıştır

- x-y eksenlerinde referans işaretleyici nokta belirlenir. Referans işaretleyici olarak göz noktaları alınmıştır.
- x-y eksenleri işaretleyicinin boyut faktörüne göre yeniden boyutlandırılır.
- İlk altı adet ana noktacığa ağırlıklar verilir.
- 40 adet işaretleyici 1'den 40'a kadar yerleştirilir. Geriye kalan 41 ile 45 arasındaki işaretleyiciler ise ilk 40 işaretleyiciye bağlı olarak yerleştirilir.


3.3 YSA Uygulaması

Bu bölümde tarafımızdan oluşturulan veri tabanındaki, normal morfolojiye sahip ve down sendromlu çocukların fotoğrafları için işaretleyici model eşleme metodu kullanarak bulunan maskelerin içerisinden, öznitelik vektörlerinin çıkartılması anlatılacaktır. Daha sonra elde edilen öznitelik vektörlerinin, MATLAB 7.0 tabanlı program ile YSA alet kutusundaki gradyant azaltmalı geri yayılım fonksiyonu traingdx kullanılarak eğitilmesi ve son olarak eğitilen vektörlerin test edilmesi ve test yöntemleri anlatılacaktır.

3.3.1 Öznitelik vektörlerinin oluşturulması

Veri tabanında bulunan her down sendromlu ve normal çocuk fotoğraflarından bölüm 3.1 anlatılan metot ile yüzdeki maskeler oluşturulmuştur. Elde edilen bu maskelerden öznitelik vektörlerinin çıkartılması için yüzdeki kritik noktalar Gülhane Askeri Tıp Akademisi Genetik Anabilim Dalında yapılan çalışma sonucunda tespit edilmiştir. Aşağıda seçilen kritik noktaların yüzdeki konumu belirtmiştir.Şekil 3.6'da ise maskedeki seçilen noktaların gösterimi görülmektedir.

- 1 numaralı nokta :** Sağ göz
- 2 numaralı nokta :** Sol göz
- 4 numaralı nokta :** Sağ kaşın sol köşesi
- 5 numaralı nokta :** Sol kaşın sağ köşesi
- 7 numaralı nokta :** Burun kökü
- 8 numaralı nokta :** Burun ucu
- 11 numaralı nokta:** Ağız orta üst kısmı
- 12 numaralı nokta :** Ağızın sağ köşesi
- 14 numaralı nokta :** Ağızın sol köşesi



Şekil 3.6: Maskedeki seçilen noktaların gösterimi

- 16 numaralı nokta :** Sol kulak üstü
- 17 numaralı nokta :** Sol kulak meme ucu
- 21 numaralı nokta :** Sağ kulak meme ucu
- 22 numaralı nokta :** Sol kulak üstü
- 28 numaralı nokta :** Burun sol kenarı
- 29 numaralı nokta :** Burun sağ kenarı
- 43 numaralı nokta :** Alının orta kısmı

Şekil 3.4'te seçilen noktaların fotoğraftaki yerleri gösterilmiştir. Seçilen noktaların birbirleriyle olan bağlantıları ve istenilen parametreler (bunlar öznitelik vektörü parametreleridir) aşağıdaki gibi belirlenmiştir.

1. 1-2 noktaları arasındaki uzaklık
2. 1-43 noktaları arasındaki uzaklık

3. 1-42 noktaları arasındaki uzaklık
4. 4-5 noktaları arasındaki uzaklık
5. 7-8 noktaları arasındaki uzaklık
6. 8-11 noktaları arasındaki uzaklık
7. 12-14 noktaları arasındaki uzaklık
8. 17-16 noktaları arasındaki uzaklık
9. 21-22 noktaları arasındaki uzaklık
10. 28-29 noktaları arasındaki uzaklık

Yukarıda sıralanan 10 adet öznitelik vektörü geri yayılım algoritmasında kullanılmak için belirlenmiştir. Aşağıdaki bölümde belirlenen 10 adet öznitelik vektörünün geri yayılım algoritmasında uygulanması anlatılacaktır.

3.3.2 Gradyant azaltmalı geri yayılım yöntemi ile eğitim

Bu bölümde gradyant azaltmalı geri yayılım yönteminin Matlab 7.0 YSA alet kutusundaki `traingdx` fonksiyonunun kullanımı anlatılacaktır.

3.3.2.1 Trainqdx

`Trainqdx` fonksiyonu kullanılarak uzun ağırlar eğitilebilir. Geri yayılım algoritmasını kullanmak için performans türevleri X yönelim değişkenleri ve ağırlıkları ile hesaplanır. Her değişken gradyant azalım momentine bağlı olarak ayarlanır.

$$dX = mc*dX_{prev} + lr*mc*dperf/dX$$

dX_{prev} ' in önceki ağırlık ve yönelim için değişir. Her epoh, eğer amaca ulaşan performans düşer ise öğrenme oranı `lr_inc` faktörü tarafından arttırılır. Eğer `max_per_inc` faktörü tarafından performans artar ise öğrenme oranı faktör `lr_dec` tarafından ayarlanmaktadır.

Eğitimin durma koşulları şunlardır;

1. Epoh değeri aşıldığında,
2. Zaman aşımına uğradığında,
3. Performans amaca ulaştığında,
4. Performansın gradyant hata oranına ulaşıldığında,

Bu dört durumdan herhangi bir koşul sağlandığında eğitim durmaktadır.

Aşağıda traingdx parametreleri örnek değerleri ile gösterilmektedir:

net.trainParam.epochs = 10; Eğitim için maksimum epoh sayısı

net.performFcn = 'sse'; Hataların karelerinin toplamına göre performans ölçer.

net.trainParam.goal = 0; Performans hedefi

net.trainParam.lr = 0.01; Öğrenme oranı

net.trainParam.lr_inc = 1.05; Yükselen öğrenme değeri

net.trainParam.lr_dec = 0.7; Düşen öğrenme değeri

net.trainParam.max_perf_inc = 1.04; En yüksek performans artışı

net.trainParam.mc = 0.9; Moment sabiti

net.trainParam.min_grad = 1e-10; Minimum performans gradyanti

net.trainParam.show = 25; Epohun işlem sırasında gösterilme sıklığı

net.trainParam.time = inf; Eğitim için maksimum zaman değeri

Kullanılan traingdx fonksiyonundan bir örnek aşağıda gösterilmektedir. Fonksiyonda farklı düğüm sayıları (10, 50, 80..), farklı çıkış değerleri (0-1, -1,1) kullanılarak sonuçlar elde edilmiştir.

P = traintdata;

T = target;

net.performFcn = 'sse';

net.trainParam.lr=0.01;

net.trainParam.lr_inc=1;

```
net.trainParam.lr_dec=0.5;  
net.trainParam.goal = 0.01;  
net.trainParam.show = 100;  
net.trainParam.epochs = 50000;  
net.trainParam.mc = 0.95;  
[net,tr] = train(net,P,T);
```

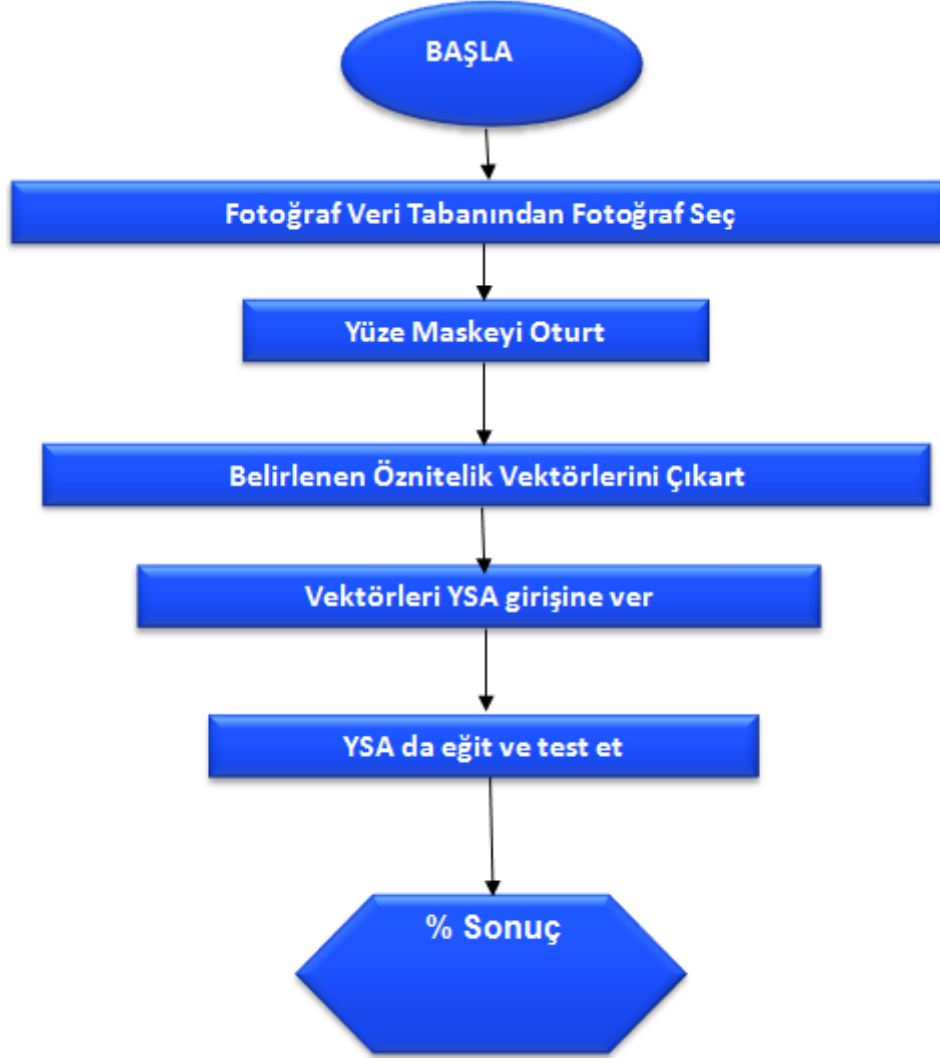
3.3.3 Test yöntemleri

Test yönteminde genel olarak iki farklı metot uygulanmıştır. Bu yöntemler “Ayrı Veri Seti” ve “Bir Veri Dışarı” yöntemidir. Bu yöntemlerin nasıl kullanıldığı aşağıdaki şekilde açıklanabilir.

1. İlk metot down sendromlu çocuklardan ilk 9 tanesinin öznelik vektörleri ile normal çocuklardan ilk 9 tanesi öznelik vektörleri eğitim seti, geriye kalan 9 down sendromlu çocuğun öznelik vektörleri ile geriye kalan 9 normal çocuk öznelik vektörü test veri seti olarak kullanılmıştır. Bu test işlemine “Ayrı Veri Seti” ile test işlemi adı verilmiştir.
2. İkinci metotta, 36 veri içerisinde bir veri dışarda tutularak kalan 35 veri ile eğitim işlemi gerçekleştirilmiş ve dışarıda tutulan veri ile test edilmiştir. Bu işlem 36 verinin tümü test edilecek şekilde tekrarlanmıştır. Bu test yöntemine “Bir Veri Dışarı” yöntemi adı verilmektedir.

Yukarıdaki bölümlerde anlatılanlar bir akış şeması ile Şekil 3.7’de gösterilmektedir. Akış şemasının en başında oluşturulan down sendromlu ve normal morfolojiye sahip çocukların yüz fotoğrafları ile fotoğraf veri tabanı oluşturulmuştur. Bu veri tabanından seçilen fotoğrafların her biri için yüz maskesi yerleştirilip yüzdeki kritik noktalar tespit edilmiştir. Kritik noktaların tespit edilmesinden sonra istenilen noktalar belirlenip o noktalar arasındaki uzaklıklar öznelik vektörü olarak seçilmiştir. Yine veri tabanındaki her bir fotoğraf için bu işlemler yapıldıktan sonra YSA’da eğitim işleminin gerçekleşmesi ve ardından

YSA'da eğitilip test işlemi gerçekleştirildikten sonra veri tabanındaki fotoğrafların her birinin yüzde olasılıkla down sendromlu olma ihtimali belirlenmiş olmaktadır.



Şekil 3.7: Yöntem akış şeması

Bu metotlar sırasıyla uygulanarak test işlemi gerçekleştirilmiştir. Test işleminden elde edilen sonuçlar ise sonuç bölümünde gösterilmiştir.

4.SONUÇLAR

Bu bölümde dismorfik görüntü analizi için kullanılan yöntemlerin sonuçlarını içermektedir. İlk kısımda oluşturulan fotoğraf veri tabanından bahsedilmektedir. İkinci kısımda elastik yüz demet grafik yöntemi ile tespit edilen noktalar gösterilmektedir. Üçüncü kısımda, ikinci kısımda elde edilen noktalardan çıkarılan öznitelik vektörleri ve YSA uygulamasının sonuçları verilmiştir.

4.1 Fotoğraf Veri Tabanı

Fotoğraf veri tabanı için down sendromlu çocukların fotoğrafları tarayıcı yardımıyla dijital ortama aktarılmıştır. Normal morfolojiye sahip çocukların fotoğrafları ise dijital fotoğraf makinesi ile çekilmiştir. Fotoğrafların tamamının aynı standartlarda olması için 128x128 boyutlarında ayarlanmıştır. Fotoğraf veri tabanı kullanılan program için kaynak oluşturmuştur. Bu sayede veri tabanındaki fotoğraflar yüz demet grafiği ile noktacık tespiti için kullanılmıştır. Aşağıda elde edilen veri tabanından örnek fotoğraflar şekil 4.1'de görülmektedir.



a)



b)

Şekil 4.1 a) ve b) Fotoğraf veri tabanından örnek fotoğraflar

4.2 YDG İle Noktacık Tespit Sonuçları

Fotoğraf veri tabanından elde edilen fotoğraflar YDG ile yüzdeki noktaların tespiti için kullanılmıştır. Şekil 4.2’de nokta tespiti yapılan fotoğraflardan örnekler gösterilmektedir. Tüm veri tabanındaki fotoğraflara bu yöntem uygulanmıştır. Fakat bir takım fotoğraflar istenilen poz ve ışık altında çekilmediğinden yüzdeki nokta tespit sonuçları istenildiği gibi olmamıştır. Bu nedenle kritik noktalardan elde edilen öznitelik vektörlerinin çıkartılması için uygun fotoğraflar seçilmiştir.




a)



b)



c)



d)

Şekil 4.2 a), b), c) ve d) YSA ile noktacık tespit sonuçları

4.3 YSA'da Ayrı Veri Deneme Yöntemi Sonuçları

YSA algoritması ayrı veri deneme yöntemi ile elde edilen sonuçlar Tablo 4.1, Tablo 4.2 ve Tablo 4.3'te gösterilmiştir. Denemeler farklı sayıda katmanlar ve farklı işaret fonksiyonları için çalışılmıştır. Farklı sayıdaki katmanlar ve işaret fonksiyonu için doğruluk değerleri farklılık göstermektedir. Çıkan sonuçların tartışması Bölüm 5'te ayrıntılı olarak anlatılmıştır.

Denemeler sırasında eğitim fonksiyonu olarak MATLAB 7.0 YSA alet kutusunun fonksiyonu olan 'traingdx' fonksiyonu kullanılmıştır.

Tablo 4.1: Ayrı Veri Deneme Yöntemi Sonuçları-1

	Deneme-1	Deneme-2	Deneme-3
GİZLİ KATMAN	10	20	30
İŞARET FONKSİYONLARI	'logsig' 'purelin'	'logsig' 'purelin'	'logsig' 'purelin'
EĞİTİM FONKSİYONU	'traingdx'	'traingdx'	'traingdx'
ÇIKIŞ	1	1	1
HEDEF	0-1	0-1	0-1
EŞİK DEĞER	0.5	0.5	0.5
DOĞRULUK :	44-88-66	71-67-69	66-55-61
HATA	0.01	0.01	0.01
EPOH	54108	22030	4950

Tablo 4.2 Ayrı Veri Deneme Yöntemi Sonuçları-2

	Deneme-4	Deneme-5	Deneme-6
GİZLİ KATMAN	50	100	100
İŞARET FONKSİYONLARI	'logsig' 'purelin'	'logsig' 'purelin'	'logsig' 'logsig'
EĞİTİM FONKSİYONU	'traingdx'	'traingdx'	'traingdx'
ÇIKIŞ	1	1	1
HEDEF	0-1	0-1	0-1
EŞİK DEĞER	0.5	0.5	0.5
DOĞRULUK:	77-44-61	66-55-61	88-55-72
HATA	0.01	0.01	0.01
EPOH	7200	4425	35000

Tablo 4.3 Ayır Veri Deneme Yöntemi Sonuçları-3

	Deneme-7	Deneme-8	Deneme-9	Deneme-10
GİZLİ KATMAN	10	20	50	80
İŞARET FONKSİYONLARI	'logsig'	'logsig'	'logsig'	'logsig'
EĞİTİM FONKSİYONU	'traingdx'	'traingdx'	'traingdx'	'traingdx'
ÇIKIŞ	1	1	1	1
HEDEF	0-1	0-1	0-1	0-1
EŞİK DEĞER	0.5	0.5	0.5	0.5
DOĞRULUK:	66-66-66	66-44-55	77-55-66	77-44-61
HATA	0.01	0.01	0.01	0.01
EPOH	9779	59328	17847	25719

Tablo 4.1’de işaret fonksiyonları sabit tutularak gizli katman sayıları arttırılmıştır. Gizli katmanların değişmesi doğruluk değerlerinin değişimine sebep olmuştur. İşaret fonksiyonları sabit tutulup gizli katman değerleri için en iyi sonuca ulaşılması amaçlanmıştır. En iyi sonuç Deneme-2’de elde edilmiştir.

Tablo 4.2’de Deneme 4 ve Deneme 5’te işaret fonksiyonları sabit tutularak gizli katman sayıları arttırılmıştır. Deneme-6’da ise aynı sayıdaki gizli katman sayısı için Deneme-5’e göre doğruluk değeri artmıştır ama epoh değerinin de arttığı gözlemlenmiştir.

Tablo 4.3'te işaret fonksiyonları değiştirilmiştir ve yeni denemeler için işaret fonksiyonları yine sabit tutularak gizli katman sayıları arttırılmıştır. Diğer tablolarda gözlenen doğruluk değerlerindeki büyük olmayan değişimler ve epoch değerlerinin yüksek olduğu gözlemlenmiştir. Aşağıdaki tablolarda bir veri dışarı yöntemi kullanılarak farklı denemeler yapılmıştır.

Tablo 4.4 Bir Veri Dışarı Yöntemi Sonuçları-1

	Deneme-1	Deneme-2
GİZLİ KATMAN	100	100
İŞARET FONKSİYONLARI	'logsig' 'purelin'	'logsig' 'logsig'
EĞİTİM FONKSİYONU	'traingdx'	'traingdx'
ÇIKIŞ	1	1
HEDEF	0-1	0-1
EŞİK DEĞER	0.5	0.5
DOĞRULUK:	68-62-65	75-70-72
HATA	0.01	0.01
EPOH	21454	28742

Tablo 4.5 Bir Veri Dışarı Yöntemi Sonuçları-2

	Deneme-3	Deneme-4
GİZLİ KATMAN	100	100
İŞARET FONKSİYONLARI	'tansig' 'tansig'	'tansig' 'purelin'
EĞİTİM FONKSİYONU	'traingdx'	'traingdx'
ÇIKIŞ	1	1
HEDEF	0-1	0-1
EŞİK DEĞER	0.5	0.5
DOĞRULUK:	69-64-66.5	74-61-67.5
HATA	0.01	0.01
EPOH	13760	23276

Farklı işaret fonksiyonları ve aynı sayıdaki gizli katmanlar için bir veri dışarı yöntemi kullanılmıştır. Tablo 4.4 ve Tablo 4.5 için işaret fonksiyonlarının değişmesi doğruluk değerini değişmesine sebep olmuştur. Bu değişim olumlu yönde gözlemlenmiştir ve her iki tablodaki doğruluk değerlerinin birbirine yakın olduğu gözlemlenmiştir.

Bir sonraki bölüm “Tartışmalar” kısmında çalışmamızdaki sınırlayıcı etkenler ve gelecekteki çalışmalar anlatılacaktır.

5. TARTIŞMALAR

Gerçekleştirilen çalışmanın ana amacı dismorfik hastalıkların görüntü analizi ile ayırt edilmesidir. Bu amaç doğrultusunda yapılan çalışmalarda yüz demet grafiği yöntemi kullanılarak yüz noktacıları tespit edilmiş ve çıkarılan öznitelik vektörlerine YSA algoritması uygulanmıştır. Böylece klinik ön tanının konulmasında hekimden hekime görülen farklılığın ortadan kaldırılması amaçlanmıştır. Çalışmanın sonucunda bireyin down sendromlu olma ihtimalinin ne kadar doğrulukta olduğu yüzde olarak belirlenebilmiştir. Tablo 5.1 ve 5.2’de bu sonuçlar toplu olarak görülmektedir.

Tablo 5.1 Genel İstatistiki Sonuçlar-1

		Deneme 1	Deneme 2	Deneme 3	Deneme 4
AYRI VERİ DENEME	Down Sendromu	%44	%71	%66	%77
	Normal Morfoloji	%88	%67	%55	%44
BİR VERİ DIŞARI	Down Sendromu	%68	%75	%69	%74
	Normal Morfoloji	%62	%70	%64	%61

Tablo 5.2 Genel İstatistiki Sonuçlar-2

		Deneme 5	Deneme 6	Deneme 7	Deneme 8	Deneme 9	Deneme 10
AYRI VERİ DENEME	Down Sendromu	%66	%88	%66	%77	%77	%66
	Normal Morfoloji	%55	%55	%44	%55	%44	%66

Yapılan istatistiki deęerlendirmeler neticesinde elde edilen genel sonular Tablo 5.1’de gsterilmektedir. Sarı ile gsterilen blm Down Sendrom ihtimal yzdesi ve normal morfoloji ihtimal yzdesi olarak verilmiřtir.

Tablo 5.1 iki farklı YSA metodu iin ıkan sonuları yzdesel olarak gstermektedir. Her iki metodun sonularının ortalamaları arasında ok byk fark gzlemlenmemiřtir. Sonu olarak bu bulgular dismorfik hastalıęın grnt analizi ile ayırt edilebileceęini gstermektedir.

5.1 alıřmadaki Sınırlayıcı Etkenler

Gerekleřtirilen alıřmalarda gerek sonularınzerinde gerekse bu sonuların karřılařtırılmasında sınırlayıcı bir takım etkenlerin varlıęı sz konusudur. Bu etkenlerin bařında veri tabanı iin ekilen fotoęraflarınzellikleri ilk sırayı almaktadır. Bu fotoęrafların ışık, odaklama, pozlama vb. gibi yapısalzelliklerinin tek tip olması gerekmektedir. Buzellikler hemen hemen her fotoęraf iin farklı deęerlerdedir. Bylelikle tek tip fotoęraf yapısından uzak kalınmıřtır. Bunun sonucunda da programın bařarısını dřmřtr.

Farklı pozlama, noktacıkların konumunu etkilemektedir. Fotoęrafların tamamının aynı standartlarda ekilmemesi znrlę olumsuz ynde etkilemiřtir. Veri tabanındaki bazı fotoęraflarda tespit edilenznelik vektrlerinin konumlarının tam istenilen yerde olmaması sebebiyle doęruluk oranının etkilendięi gzlemlenmiřtir.

Hem down sendromlu hem de normal morfolojiye sahip ocukların fotoęraflarının sayısının az olması doęruluęu etkileyen dięer bir faktrdr. Kořulların istenildięi gibi gerekleřtirilebilmesi iin uzun bir zaman dilimine ihtiya duyulmaktadır. Dolayısıyla gerekleřtirilecek daha kapsamlı ve uzun sreli bir alıřma ile bařarılı sonular elde edilebilir.

5.2 Gelecekteki Çalışmalar

Elastik Demet Grafik metodunun down sendromlu hastalarda da kullanılabilirliğinin gösterilmesi ile bu modelin gelecekte devam edecek bir takım çalışmalara temel oluşturması hedeflenmektedir.

Gelecekte gerçekleştirilmesi mümkün olan çalışmalardan birisi, diğer dismorfik hastalıklara uygulayarak geniş bir uygulama alanı oluşturulmasıdır. Bunun içinse Ulusal bir fotoğraf veri tabanı oluşturmak ve bu veri tabanı ile çalışmak deneysel başarıyı arttıracaktır. Böylelikle klinik ön tanı da standardizasyonu yakalamak mümkün olacaktır.

Sonuç olarak; yapılan bu çalışma dismorfik hastalığa sahip kişinin yüz haritasının çıkartılmasında ve YSA metodu uygulayarak klinik ön tanın konulmasında başarı sağlandığını göstermektedir.

KAYNAKLAR LİSTESİ

- [1] Aase M. J., Diagnostic Dysmorphology, Plenum Medical Book Co.,1990
- [2] Loos S.H., Wieczorek D.,Wurtz R.,Malsburg C.,Horsthemke B., Computer-based recognition of dysmorphic faces, European Journal of Human Genetics (2003) 11, 555–560
- [3] Edwards JH, Harnden DG, Cameron AH. A new trisomic syndrome. Lancet 1960; 787–789
- [4] Smith DW, Patau K, Therman E. A new autosomal trisomy syndrome: Multiple congenital anomalies caused by an extra chromosome. J Pediatr 1960; 57: 338–345
- [5] Lynch L, Berkowitz RL: First trimester growth delay in trisomy 18. Am J Perinatol 1989; 6: 237-39
- [6] Laurence E.S, Leslie A.C, Karin M.S. Ultrasonographic Diagnosis of Trisomy 18. J Ultrasound Med 1998; 17: 327-331
- [7] Lynch L, Berkowitz RL: First trimester growth delay in trisomy 18. Am J Perinatol 1989; 6: 237-39.
- [8] Patau K, Smith DW, Therman E, Inhorn SL,Wagner HP: Multiple congenital anomaly caused by an extra chrosome. Lancet 1:790,1960.
- [9] Smith DW: Recognizable patterns of hurman malformations. 2nd Edition, Philadelphia, WB Saunders, 1976.
- [10] Eubanks SR, Kuller JA, Amjadi D, Powell CM:Prenatal diagnosis of mosaic trisomy 13: A case report. Prenatal Diagnosis, 18 (9):971-974, 1998.

- [11] Misanovic V, Jonuzi F, Biscevic E, Uzicanin S, Vegar S: The Patau syndrome. *Med Arh*, 56(3 Suppl 1):42-43, 2002.
- [12] Brewer CM, Holloway SH, Stone DH, Carothers AD, FitzPatrick DR: Survival in trisomy 13 and trisomy 18 cases ascertained from population based registers. *J Med Genet*, 39(9):54, 2002
- [13] Warkany J, Passarge E, Smith LD: Congenital malformations in autosomal trisomy syndromes. *Am J Dis Child*, 112:502,1966.
- [14] Fuloria M: The newborn examination Emergencies and common abnormalities involving the skin, head, neck, chest and respiratory and cardiovascular systems. *American Family Physician*, 65(1):61-68, 2002.
- [15] Rygl M, Kalousova J, Pycha K, Styblova J, Snaidauf J: Current results in treatment of omphalocele and gastroschisis. *Ceska Gynecol*, 69(1):55-59, 2004.
- [16] Expression profiling reveals fundamental biological differences in acute myeloid leukemia with isolated trisomy 8 and normal cytogenetics, *PNAS*, January 30, 2001, vol. 98, no. 3, pp.1124-1129
- [17] Clinical and molecular studies in full trisomy 22: further delineation of the phenotype and review of the literature. Bacino CA, Schreck R, Fischel-Ghodsian N, Pepkowitz S, Prezant TR, Graham JM ,Medical Genetics Birth Defects Center, Cedars-Sinai Medical Center, UCLA School of Medicine, *American Journal Of Medical Genetics*. 1995 May 8;56(4):359-65.
- [18] Partial trisomy 22: a recognizable syndrome. Garlinger P, McGeary SA, Magenis E., *Clinical Genetics*, 1977 Jul;12(1):9-16.
- [19] Origin of acrocentric trisomies in spontaneous abortuses, *Human Genetics*, Volume 40, Number 1, January, 1977.

- [20] Alp M. N., Oral D., Budak T., Down Sendromu Ön Tanılı 584 Olguda Sitogenetik Çalışma, Dicle Tıp Dergisi, 2007 Cilt: 34, Sayı:4
- [21] Nussbaum RL, McInnes RR, Willard HF. Thompson & Thompson Genetics in Medicine, 6th edn. Philadelphia: W.B.Saunders Company, 2001: 157-162.
- [22] Hall, J.G., Froster, U.G., Allanson, J.E., Handbook of Normal Physical Measurements, United States, 1995
- [23] http://www.riversideonline.com/health_reference/Disease-Conditions/DS00182.cfm
- [24] J-L Guéant, G Anello, P Bosco, R-M Guéant-Rodríguez, A Romano, C Barone, P Gérard, C Romano, Homocysteine and related genetic polymorphisms in Down's syndrome IQ, Journal of Neurology Neurosurgery and Psychiatry, 2005; 76:706-709
- [25] M. Turk and A. Pentland, "Eigenfaces for Recognition", Journal of Cognitive Science, s. 71-86, 1991
- [26] H.K. Ekenel, S.Y. Bilgin, İ. Eden, M. Kirişçi, H. Erdoğan, A. Erçil Combining Face and Voice Modalities for Person Verification from Video Sequences, XII. National Conference on Signal Processing, 2004.
- [27] Belhumeur, P.N. Hespanha, J.P. Kriegman, D.J. "Eigenfaces vs. Fisherfaces: recognition using class specific linearprojection," IEEE Transactions on Pattern Analysis and Machine Intelligence, Volume: 19, Issue: 7, Jul 1997 pp. 711-720.
- [28] Kil D.H., Shin F.B., "Pattern Recognition and Prediction with Applications to Signal Characterization", AIP Press, USA, (1996)

- [29] Face Recognition by Independent Component Analysis Marian Stewart Bartlett, Member, IEEE, Javier R. Movellan, Member, IEEE, and Terrence J. Sejnowski, Fellow, IEEE s.1
- [30] L. Wiskott, J. M. Fellous, N. Kruger, and C. von der Malsburg, "Face recognition by elastic bunch graph matching," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 19, pp. 775-779, 1997.
- [31] Daugman, J. G. (1988). Complete discrete 2-D Gabor transform by neural networks for image analysis and compression. *IEEE Trans. on Acoustics, Speech and Signal Processing*, pp.1169-1179.
- [32] Potzsch, M., Kruger, N., and von der Malsburg, C. (1996). Improving object recognition by transforming Gabor Filter responses. *Network: Computation in Neural Systems*, pp.341-347.
- [33] Pollen, D. A. and Ronner, S. F. (1981). Phase relationship between adjacent simple cells in the visual cortex. *Science*, pp.1409-1411.
- [34] Olshausen, B. A. and Field, D. J. (1996). Emergence of simple-cell receptive field properties by learning a sparse code for natural images. *Nature*, pp.607-609.
- [35] Fleet, D. J. and Jepson, A. D. (1990). Computation of component image velocity from local phase information. *Int'l J. of Computer Vision*, pp.77-82.
- [36] Kruger, N. (1997). An algorithm for the learning of weights in discrimination functions using a priori constraints. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, pp.764-768.
- [37] Kruger, N., Mañel, E., Pagel, M., and von der Malsburg, C. (1998). Autonomous learning of object representations utilizing self-controlled movements. In *Proc. of Neural Networks in Applications*, NN'98, Magdeburg, Germany, pp.25-29.

- [38] James, W. (1890), "Psychology (Briefer Course)", New York: Holt, , Chapter XVI,'Association", pp. 253-279.
- [39] McCulloch, W. S. and Pitts, W. A. (1943),"A logical calculus of the ideas immanent in nervous activity", Buttetin of Mathematics and Biophysics, 5, pp.115-133.
- [40] Kohonen T., (1987), State of the art in neural computing, Proc.of the IEEE first international conferans on neural networks, San Diago, 21-24 June 1987, California, Vol 1., pp 77-91.
- [41] Hebb, D. O., (1949), "The organization of behaviour", New York: Wiley, Introduction and Chapter 4,"The first stage of perception: growth of the assemby", pp. 60-78.
- [42] Farely, B. G. and Clark, W. A. (1954),"Simulation of self-organizing systems by digital computers", IEE Transactions of Professional Group of Information Theory, pp. 76-84.
- [43] Caianiello, E. R.(1961),"Outline of a theory of thought-processes and thinking rnachines", Journal of Theoretical Biology, 2, pp. 204-235.
- [44] Widrow, B. and Hoff, M. E. (1960), "Adaptive switching circuits", WESTCON Convention, Record Part IV, 1960, pp. 96-104.
- [45] Rosenblatt, F.(1958), "The perceptron: A probabilistic model for information storage and organization in the brain", Psychoanalytic Review,pp. 386-408.
- [46] Nilson, N. J., (1965),'Learning Machines", McGraw-Hill
- [47] Minsky, M. and Papert, 5. (1969),"Perceptrons", MIT Press, Cambridge, MA.

- [48] Ercan Öztemel ; Yapay Sinir Ağları , Papatya Yayıncılık, 2003
- [49] Kohonen, T., "Correlation matrix memories", IEEE Transaction on Computers, 1972, pp. 353-359.
- [50] Kohonen, T. (1982), "Self-organized formation of topologically correct feature maps", Biological Cybernetics, 1982, pp. 59-69.
- [51] Grossberg, S. A. (1973), "Contour enhancement, short term memory, and consularities in reverberating neural networks", Studies in Applied Mathematics, 1973, pp. 213-257.
- [52] Grossberg, S. A., "Studies of mind and brain", Reidel Press, Dordrecht, Holland., 1982.
- [53] Grossberg, S. A., "Neural networks and natural intelligence", MIT Press, Cambridge, MA., 1988.
- [54] Carpenter, G. A. and Grossberg, S. A., "ART2: self-organization of stable category recognition codes for analog input patterns", Applied Optics, 26(3), pp. 4919-4930, 1987.
- [55] Fukushima, K., "Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position", Biological Cybernetics, 36, pp. 193-202., 1987.
- [56] Fukushima, K., "Neocognitron: a new algorithm for pattern recognition of deformations and shifts in position", Pattern Recognition, 15, 1982, pp. 455-469.
- [57] Fukushima, K., Miyake, S. and Ito T. (1983), "Neocognitron: a neural network model for a mechanism of visual pattern recognition", IEEE Transactions on Systems, Man and Cybernetics, SMC-13.

- [58] Fukushima, K., "A neural network model for selective attention in visual pattern recognition", *Biol. Cybernetics*, 55, 1986, pp. 5-15.
- [59] Hopfield, J. J. (1982), "Neural networks and physical systems with emergent collective computational abilities", *Proceedings of the National Academy of Sciences*, 79, , pp. 2554-2558.
- [60] Hopfield, J. J. (1982) , "Neurons with graded response have collective computational properties like those of two state neurons", *Proc. Natl. Acad. Sci.*, 81, pp. 3088-3092.
- [61] Rumelhart, D. E. and McClelland, J. L. (1986), "Parallel distributed processing, explorations in the microstructure of cognition", vol 1: *Foundations*, MIT Press, Cambridge, MA.
- [62] McClelland, J. L. and Rumelhart, D. E. (1986), "Parallel distributed processing, explorations in the microstructure of cognition", Vol 2: *Psychological and biological models*, MIT Press, Cambridge, MA.
- [63] Rumelhart, D. E. and McClelland, J. L. (1988), "Parallel distributed processing, explorations in the microstructure of cognition, A handbook of models, programs, and exercises", MIT Press, Cambridge, MA.,
- [64] Rumelhart, D. E., Hinton, D. E. and Williams, J. (1986), "Learning representation by backpropagating errors" *Nature* 323(9), pp. 533-536.
- [65] Parker, D. B. (1985), "Learning-logic", *M.I.T. Cen. Computational Res. Economics Management Sci.*, Cambridge, MA, TR-47.
- [66] Werbos, P. J. (1974), "Beyond regression: new tools for prediction and analysis in the behavioural sciences", PhD. dissertation, Committee on Appl.Math., Harvard Univ., Cambridge, M. A.

- [67] Broomhead, D. S., Lowe, D (1988), "Radial basis-functions, multi-variable functional interpolation and adaptive networks", Royal signals and radar establishment memorandum 4148.
- [68] Specht, D. K (1988), "Probabilistic neural networks for classification, mapping, or associative memory", IJCNN Conference on Neural Networks, Vol. 1, San Diego, pp. 525-532.
- [69] Specht, D. F. (1991), "A general regression neural network", IEEE Transactions on Neural Networks, vol. 2, No. 6, pp. 568-576.
- [70] Haykin, S. (1994), "Neural Networks, A Comprehensive Foundation", Macmillan College Publishing Company.
- [71] Ban, M.L., Kiemann J.A., (1988), The Human Nervous System. An Anatomical Viewpoint. Fifth Edition. Harper International.
- [72] Sagirolu Ş., Beşdok E., Mühendislikte Yapay Zeka Uygulamaları-I, Ufuk Kitap Kirtasiye-Yayıncılık Tic. Ltd. Şti. 2003
- [73] Harvey, R. L., (1994), Neural Network Principles. Prentice Hall. New Jersey.
- [74] Hassoun, M. H., (1995), Fundamentals of Artificial Neural Networks. MIT Press.
- [75] Ripley, B.D., (1996), Pattern Recognition and Neural Networks, Cambridge, Cambridge University Press.
- [76] Reed, R.D., Marks, R.J., II, (1999), Neural Smoothing, Supervised Learning in Feedforward Artificial Neural Networks, Cambridge, MA, The MIT Press, ISBN 0-262-18190-8.

- [77] Maren, A., Harston C., Pap, R., (1990), Handbook of Neural Computing Applications, Academic Press, London, ISBN 0-12-471260-6
- [78] Reed, R.D., Marks, R.J, II, (1999), Neural Smothing, Supervised Learning in Feedforward Artificial Neural Networks, Cambridge, MA, The MIT Press, ISBN 0-262-18190-8.
- [79] Balakrishnan, P.V., Cooper, M.C., Jacob, V.S., Lewis, P.A., (1994), A study of the ciassification capabilities of neural networks using unsupervised learning, A comparison with k-means clustering, Psychometrika, vol.59, pp.509-525.
- [80] Chen, F. C., (1990), Backpropagation Neural Networks for Nonlinear Selftuning Adaptive Control, IEEE Control Systems Magazine, pp 44-48.
- [81] Hecht-Nielsen, R., (1989), Theory of Backpropagation Neural Networks. Proceedings of the International Joint Conference on Neural Networks, Washington, vol. 1, pp.593-605.
- [82] Riedmiller, M., Braun, 11., (1993), A Direct Adaptive Method for Faster Backpropagation Learning, The RPROP Algorithm, Proceedings of the IEEE International Conference on Neural Networks, San Francisco, CA, March,vol.1,pp.586-591.
- [83] Werbos, P.J., (1990), Backpropagtion through time, What it is and how to do it, Proeedings of the IEEE, 78, 1550-1560.
- [84] Mathworks Inc., (1998), Matlab 5.3 Neural Network Toolbox, Users Guide, 5. Printing, Version 3, Mathworks Inc.
- [85] Vogl, T. P., J.K. Mangis, A.K. Rigler, W.T. Zink, and D.L. Alkon, "Accelerating the convergence of the backpropagation method," Biological Cybernetics, vol. 59, pp. 257-263, 1988.

- [86] Beale, E. M. L., (1972), A Derivation of Conjugate Gradients, Numerical Methods for Nonlinear Optimization, London, Academic Press.
- [87] Senaratne R., Halgamuge S., Optimal Weighting of Landmarks for Face Recognition, Journal of Multimedia, Vol. 1, No. 3, June 2006
- [88] J. Kennedy and R. C. Eberhart, "Particle swarm optimization," presented at International Conference on Neural Networks, Perth, Australia, 1995.
- [89] Y. Shi and R. C. Eberhart, "Parameter selection in particle swarm optimization," presented at Seventh International Conference on Evolutionary Programming, 1998.
- [90] M. Clerc and J. Kennedy, "The particle swarm -Explosion, stability, and convergence in a multidimensional complex space," IEEE Transactions on Evolutionary Computation, vol. 6, pp. 58-73, 2002
- [91] Y. Shi and R. C. Eberhart, "Empirical study of particle swarm optimization," presented at Proceedings of the IEEE Congress on Evolutionary Computation (CEC 1999), Piscataway, NJ, 1999.
- [92] Ratnaweera, S. K. Halgamuge, and H. C. Watson, "Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients," IEEE Transactions on Evolutionary Computation, vol. 8, pp. 240-255, 2004.
- [93] S. Patchararungruang, S. K. Halgamuge, and N. Shenoy, "Optimized rule-based delay proportion adjustment for proportional differentiated services," IEEE Journal on Selected Areas in Communications, vol. 23, pp. 261-276, 2005.