

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

PERİFERİK YAYMA SONUÇLARININ BİLGİSAYARDA YORUMLANMASI

YÜKSEK LİSANS TEZİ

Tolga KARADENİZ

ŞUBAT 2008
TRABZON

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

PERİFERİK YAYMA SONUÇLARININ BİLGİSAYARDA YORUMLANMASI

Bilgisayar Mühendisi Tolga KARADENİZ

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“Bilgisayar Yüksek Mühendisi”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 22.01.2008

Tezin Savunma Tarihi : 18.02.2008

Tez Danışmanı : Prof. Dr. Vasif V. NABİYEV

Jüri Üyesi : Prof. Dr. Rifat YAZICI

Jüri Üyesi : Doç. Dr. Temel KAYIKÇIOĞLU

Enstitü Müdür V. : Doç. Dr. Salih TERZİOĞLU

Trabzon 2008

ÖNSÖZ

Öncelikle beni bu günlere getiren ve her zaman yanımda olan babama, anneme, kardeşime ve tüm aile bireylerime minnettarım.

Çalışmamı en vazgeçtiğim zamanlarda bunu kabul etmeyen, sürekli moral veren ve desteğini hiç eksik etmeyen danışmanım Sayın Prof. Dr. Vasıf NABİYEV'e hoş görüşünden ve özverisinden dolayı teşekkürü bir borç bilirim.

Çalışmalarında bilgilerinden yararlandığım, en zor anlarımda yanımda olan arkadaşlarıma teşekkür ederim.

Tez yazımı süresince iş yükü konusunda anlayışlı davranan ve ilham veren öncelikle KTÜ. Enformatik Bölümü Başkanı Doç. Dr. Ahmet ÇOLAK'a ve birlikte çalıştığım tüm mesai arkadaşlarıma verdikleri destekten ötürü şükranlarımı sunarım.

Lisansüstü çalışmamı yarıda bırakmamam, mutlaka teslim etmem konusunda beni ikna etmek için konuşan ve gerekli kolaylıkları sağlayan KTÜ Bilgi İşlem Dairesi çalışanlarına teşekkürü borç bilirim.

Bu çalışmanın hazırlanması ve tamamlanması esnasında bana yardımcı olan adını saymadığım insanlara teşekkür ederim.

Saygılarımla...

TOLGA KARADENİZ

Trabzon, 2008

İÇİNDEKİLER

	Sayfa No
ÖNSÖZ.....	II
İÇİNDEKİLER.....	III
ÖZET.....	VI
SUMMARY.....	VII
ŞEKİLLER DİZİNİ.....	VIII
TABLolar DİZİNİ.....	X
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Çalışmanın Amacı ve Genel Yapısı.....	1
1.2.1. Tıbbi Tanı Sistemlerinde Bilgisayarın Kullanım Amacı.....	2
1.3. Anemi.....	4
1.3.1. Anemi Tanımı.....	4
1.3.2. Kırmızı Kan Hücrelerinin Başlıca Görevi.....	5
1.3.3. Kırmızı Kan Hücrelerinin Yapılması.....	5
1.3.4. Hemoglobın İçin Normal Düzeyler.....	6
1.3.5. Anemide Görülen Belirtiler.....	7
1.3.6. Aneminin Nedenleri.....	7
1.3.7. Anemi Türleri.....	8
1.3.8. Anemi Tanısında Kullanılan Laboratuvar Testleri.....	8
1.3.9. Demir Eksikliği Anemisi.....	9
1.3.10. Demir Metabolizması.....	10
1.3.11. Demir Eksikliğinin Ortaya Çıkış Nedenleri.....	10
1.3.12. Demir Eksikliği Tanısının Konulması.....	11
1.3.13. Tedavi.....	12
1.3.14. Periferik Yayma.....	12
1.4. Ön İşlemler.....	15
1.4.1. Sayısal Görüntünün Kullanılması.....	16
1.4.2. Renk Bilgisi.....	17
1.4.3. Gri Seviye Dönüşümü.....	18

1.4.4.	Eşikleme (Thresholding)	20
1.4.5.	Filtreleme İşlemleri.....	22
1.4.6.	Evrişim (Convolution) İşlemi.....	22
1.4.7.	Kenar Güçlendirme (Algılama) Filtreleri	23
1.4.8.	Yumuşatma (Smoothing).....	25
1.4.8.1.	Ortalama Filtresi	25
1.4.8.2.	Gauss Filtresi	26
1.5.	Şekil Tespiti	28
1.5.1.	Hough Dönüşümü (Hough Transform)	28
1.5.1.1.	Görüntü Üzerinde Doğruların Tespiti.....	29
1.5.2.	Hough Dönüşümü Algoritması.....	30
1.5.3.	Çember Tespiti (CHT).....	34
1.5.4.	Eğim Vektör Çiftleri Kullanılarak Çember Tespiti	38
1.6.	Bölütleme.....	39
1.6.1.	Watershed Dönüşümü.....	40
1.6.1.1.	Watershed Dönüşüm Yöntemleri	40
1.6.1.2.	Görüntü Üzerinde Watershed Uygulaması.....	42
1.7.	Yapay Sinir Ağları (YSA) ile Tanıma	43
1.7.1.	Literatürdeki YSA Tanımları.....	44
1.7.2.	YSA'nın Uygulama Alanları	45
1.7.3.	YSA'nın Avantajları	45
1.7.4.	YSA'nın Dezavantajları	47
1.7.5.	YSA Yapısı.....	49
1.7.6.	Biyolojik Sinir Sistemi	49
1.7.7.	Sinir Hücresi (Nöron)	49
1.7.8.	YSA'nın Yapısı	51
1.7.9.	YSA'nın Tasarımı.....	52
1.7.10.	YSA Ağ Yapısının Seçimi.....	53
1.7.11.	Öğrenme Algoritmasının Seçimi	53
1.7.12.	Ara Katman Sayısını Belirleme	54
1.7.13.	Nöron Sayısının Belirlenmesi.....	55
1.7.14.	Normalizasyon.....	55
1.7.15.	Basit Algılayıcı Modeli (Perseptron).....	56

1.7.16.	Çok Katmanlı Sinir Ağları.....	57
1.7.17.	YSA Öğrenme Algoritmaları.....	58
1.7.18.	Temel Öğrenme Kuralları.....	58
1.7.19.	Hebb Kuralı	58
1.7.20.	Delta Kuralı	59
1.7.21.	Kohonen Kuralı	59
1.7.22.	Hopfield Kuralı.....	59
1.7.23.	Öğrenme Algoritmaları.....	60
1.7.23.1.	Geriyayılım Algoritması.....	60
2.	YAPILAN ÇALIŞMALAR.....	63
2.1.	Gri seviye dönüşümü	63
2.2.	Hücre Sınırlarının Belirlenmesi.....	64
2.3.	Hough Dönüşümünün Probleme Uygulanması	65
2.3.1.	Etiketleme	68
2.3.2.	Yapay Sinir Ağı	69
3.	SONUÇLAR.....	74
4.	ÖNERİLER	75
5.	KAYNAKLAR.....	76
6.	EKLER	78
ÖZGEÇMİŞ		

ÖZET

Teknolojinin gelişimiyle günümüzde tıbbi görüntülerin bilgisayarlı yorumlaması büyük önem kazanmaktadır. Çalışmada periferik yayma sonuçlarının bilgisayarda yorumlanmasıyla sık rastlanan demir eksikliği anemisinin yorumlanması amaçlanmaktadır.

Anemi, kan hemogloblin düzeyinde veya kırmızı kan hücreleri sayısında azalma ve buna bağlı gelişen bulgulardır. Periferik Yayma, kanın şekilli elamanlarının mikroskop altında gözle değerlendirilmesi kandamlaşmadaki hücrelerin özel bazı işlemlere tabi tutularak boyanması işlemidir.

Çalışma görüntü işleme ve tanıma olmak üzere iki bölümden oluşmaktadır. Görüntü üzerinde bölütlemenin daha doğru şekilde gerçekleştirilebilmesi için kenar güçlendirme ve yumuşatma operatörleri ve matematiksel işlemler kullanılmıştır. Bölütleme sırasında watershed, hough dönüşümü, histogram analizleri ve Otsu tarafından tanımlanan eşikleme yöntemi kullanılmıştır.

Problemde, görüntü üzerindeki şekil tespitinde ve elde edilen şekillerin gruplandırılması için çok katmanlı geri yayımlı yapay sinir ağı kullanılmıştır. Yapay sinir ağları (YSA), günümüzde görüntü tespitinde literatürde popüler bir konu olmakla, tahmin sistemlerinde de kullanılabilirlerdir. Geliştirilen YSA farklı katman sayıları, farklı giriş-çıkış sayıları için birçok örnek setiyle eğitilmiştir. YSA sisteminin kullanımı ve gerçekleştirilen çalışmaların sonuçları ayrıntılı olarak açıklanmıştır.

Microsoft Visual Studio 2005 platformunda Visual C# programlama dili ile Windows Application projesi olarak yazılım geliştirilmiştir. Yazılım, sonuçlar üzerinde yöntemlerin tekrar işlem yapılabilecek şekilde tasarlanmıştır. Her bir yöntem, ayrı yapılar içinde oluşturulmuştur. Varsayımlar, sınırlamalar ve nasıl kullanılacağı açıklamaları ile kod içinde ayrıntılı olarak verilmiştir. Böylece daha sonra yapılabilecek çalışmalara eklenebilirliği ve olası zaman tasarrufu sağlanması amaçlanmıştır.

Anahtar Kelimeler: Periferik Yayma, Watershed dönüşümü, Otsu Eşikleme, Hough dönüşümü, Demir Eksikliği Anemisi, Yapay Sinir Ağı

SUMMARY

Evaluating The Results Of Peripheral Propagation On The Computer

With the advancements in technology, in today's world, computirized medical imaging has become very important. The purpose of this application is to diagnose Iron Deficiency Anemia by evaluating the results of Peripheral Propagation on the computer.

Anemia is the reduction in blood hemoglobin level or red blood cell count and developed symptoms related to this reduction. Peripheral Propagation is the process of examining the particals in the blood under microscope and paint the blood cells by using special techniques.

Application is comprised of two parts: processing and recognizing. In order to achieve better segmentation results on the image, side strengtening and relaxing operators as well as mathematical logarithms were used. During segmentation, a treshold method, that was defined by Otsu, histogram analysis, Hough transform and Watershed methods, is used.

In the problem, Artificial Neural Network (ANN) is used to identify the images on the picture and to group these images. ANN is a popular topic in image recognition literature and can be used in forecasting systems. Developed ANN was trained for different layered numbers and input-output numbers by many sample sets. How this ANN system is used and the results of developed applications are explained in detail.

Software was developed in a way that methods can be used over results, repeatedly. Development platform is MS Visual Studio 2005 and the software language used is Visual C#. Every method was created as different structure. Assumptions, constraints and how to operate the software are provided in the code in detail. Thus, it could be used in other applications and could be very time efficient.

Key Words: Peripheral propagation, Iron deficiency anemia, Watershed transform, Otsu's thresholding method, Hough transform, Artificial Neural Network.

ŞEKİLLER DİZİNİ

	Sayfa No
Şekil 1. Bitişik ve ayrık hücre şekilleri	1
Şekil 2. Çalışma düzeni	2
Şekil 3. Kan hücresi	5
Şekil 4. Periferik yayma.....	13
Şekil 5. Periferik yayma sonuçları	14
Şekil 6. İyi kurutulmamış bir yaymada su partikülleri	14
Şekil 7. Boya artıkları trombosit izlenimi veriyor	15
Şekil 8. Gri dönüşümün farklı renk tonlarıyla gösterimi	19
Şekil 9. Histogram ve otsu yöntemi ile hesaplanan eşik değeri.....	21
Şekil 10. Convolution işlemi şeması.....	23
Şekil 11. Bir boyutlu gauss dağılımı grafiği	26
Şekil 12. İki boyutlu gauss dağılımı grafiği.....	27
Şekil 13. İkili görüntüde tespit edilen doğruların gösterimi	31
Şekil 14. Hough dönüşümü (Θ , p) parametreleri.....	31
Şekil 15. (P) değerinin hesaplanması.....	32
Şekil 16. Hough sinüs eğrisi	33
Şekil 17. (Θ ,p) çiftlerini doğrulayan nokta yoğunlukları.....	33
Şekil 18. CHT çember araştırması	18
Şekil 19. Çember çevresi hesaplama	19
Şekil 20. Faklı (Θ) açılarıyla yapılan çember taramaları.....	36
Şekil 21. CHT uygulama sonucu	37
Şekil 22. Tespit edilen çemberlerin orjinal görüntü üzerinde tespiti.....	37
Şekil 23. Eğim vektörleri arası açı bilgileri	38
Şekil 24. Watershed topografik görünümü	40
Şekil 25. Watershed ile ayrılmış bölgeler	41
Şekil 26. Gürültülü yüzey ve aşırı bölütleme	42
Şekil 27. Watershed yöntemi ile aşırı bölütlenmiş bir görüntü	42
Şekil 28. Biyolojik sinir sisteminin blok gösterimi	49
Şekil 29. Biyolojik sinir hücre şekli.....	50

Şekil 30.	Yapay sinir ağı modeli.....	52
Şekil 31.	Geri yayılım algoritmasının akış şeması	61
Şekil 32.	Eşikleme sonuçları.....	64
Şekil 33.	CHT uygulama sonucu	65
Şekil 34.	Hough dönüşümü için boşaltma ile hazırlanan veri	66
Şekil 35.	Hough dönüşümü için geliştirilen yazılım arayüzü	67
Şekil 36.	İlk bulunan çember	67
Şekil 37.	Eşleşen piksel değeri 70 seçildiğinde bulunan çemberler	67
Şekil 38.	Tespit edilen çember merkezleri.....	68
Şekil 39.	İkili görüntünün etiketlenmesi	68
Şekil 40.	Etiket yoğunluk analiz arayüzü	69
Şekil 41.	Eğitim seti oluşturma arayüzü	72
Şekil 42.	YSA eğitim arayüzü	72


TABLolar DİZİNİ

	Sayfa No
Tablo 1. İnsanlardaki normal kan değerleri	6
Tablo 2. Kenar güçlendiren filtreler ve sonuçları	24
Tablo 3. Ortalama filtresi sonucu.....	26
Tablo 4. Gauss Filtresi uygulanan görüntü	27
Tablo 5. Geleneksel algoritmalar ile YSA'ların kıyaslanması	48
Tablo 6. YSA türleri ve kullanım amaçları.....	53
Tablo 7. Öğrenme algoritmaları ve uygulandıkları alanlar.....	54

1. GENEL BİLGİLER

1.1. Giriş

Hücre tespitinde, görüntü üzerindeki ayırık hücrelerin belirlenmesinin yanında, bitişik hücrelerin ayrıştırılabilmesi kapsamaktadır. Şekil 1’de üzerinde çalışılan ayırık ve bitişik hücre şekli gösterilmektedir.



Şekil 1. Bitişik ve ayırık hücre şekilleri

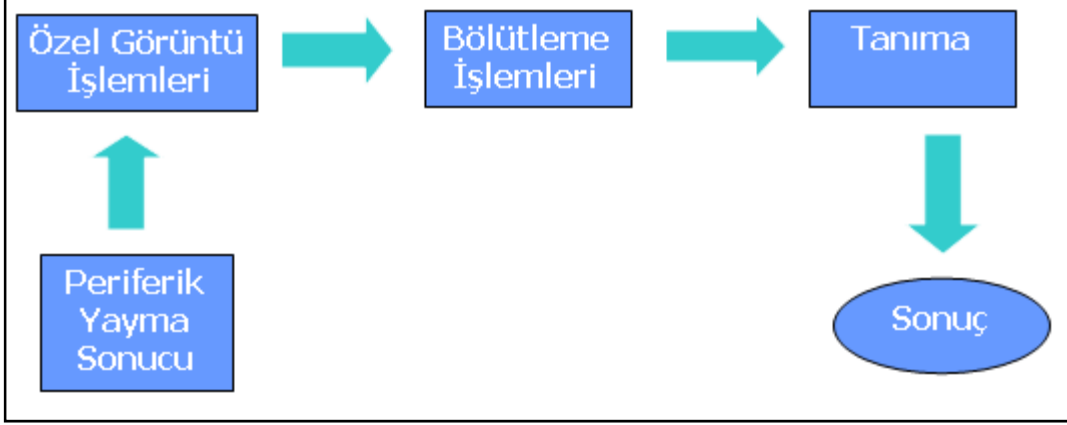
Hücre tanıma ile dikkate alınmayacak hücreler elenerek incelenecek olan hücreler tespit edilir. Hücrelerdeki farklılıklar belirlenmekte ve isimlendirilmektedir. Hücrelerin bitişik olması, üst üste gelmesi hücre yapısındaki farklılığın tespitinde hata oranını artırmaktadır.

1.2. Çalışmanın Amacı ve Genel Yapısı

Çalışmada, periferik yayma görüntüsü üzerinde yapılan incelemeyle ayırık hücrelerin tespiti, bitişik hücrelerin ayrıştırılıp ele alınması ve böylece tespit edilen hücrelerin tanınması amaçlanmıştır.

Sistemin hücreyi elde edebilmesi için görüntüdeki artalanı eleyip hücreleri belirlemesi gerekmektedir. Bu amaçla çalışma hücre tespiti, bitişik hücrelerin ayrıştırılması ve ayırık

hücrelerin tanınması olarak üç temel kısımdan oluşmaktadır. Şekil 2’de belirtilen çalışma düzeni şema ile gösterilmiştir.



Şekil 2. Çalışma düzeni

Başlangıç olarak bu konuda gerçekleştirilmiş olan çalışmalardan ve bilgisayarın bu uygulama alanındaki kullanım nedenlerinden bahsedilecektir.

1.2.1. Tıbbi Tanı Sistemlerinde Bilgisayarın Kullanım Amacı

Bilgisayar destekli sistemler tıbbi alanda incelenecek örneğin, (kan, gaita, idrar, doku vb.) temininden incelenmesine ve tanı konulmasına kadar kullanılabilir. Hastadan örnek alan aletler olduğu gibi bunları mikroskopta incelenecek preparatlara yerleştiren ve görüntüsünü alan sistemler de geliştirilmiştir.

Bilgisayar ortamında teşhis koyabilmek için kullanılan yöntem, görüntü üzerindeki şekillerin bilgisayar tarafından farklı yöntemlerle incelenmesi, araştırılması ve uzman sistemler kullanılarak teşhisin konulmasıdır. Uzman sistemler aynı zamanda diğer laboratuvar bulgularının (kan değerleri, kalp ritim sayısı, şeker, kolesterol, vs) sonuçlarına göre de karar vermek için geliştirilmeye çalışılmıştır. Programların, hekimlerin verebileceği kararları vermesi amaçlanmaktadır. Burada tanıda kullanılan yöntemlerin çoğu nedeniyle çalışmalar sürdürülmektedir.

Tanının bilgisayar ortamında konulmak istenmesinin nedeni, bilgisayarın girdiği diğer sektörlerde olduğu gibi birkaç ana başlıkta açıklanabilmektedir:

Bilgisayarlar;

- Programlandıkları konuda üşengeçlik veya dikkatsizlik yapmamaktadırlar.
- Yorulmamaktadırlar.
- Eğitim masrafı olmamaktadır. (Bir işi yapmak için geliştirilen bir bilgisayar programı, diğer bilgisayara anında kopyalanabilmektedir. Kopyalanan programların tamamen aynı şekilde çalışacağı bilinmektedir. Oysaki insan için bir eğitim süreci gerekmede ve uygulamada insanın öğrenme derecesine bağlı olarak aksaklıklar olmaktadır.)
- Gün içinde ve günlerce verdiği kararlarda bir tutarsızlık olmayacaktır. İnsan duygusal ve biyolojik bir varlık olması nedeniyle aynı durum karşısında farklı zamanlarda farklı sonuçlara ulaşabilmektedir.
- İnsandan daha kısa sürede sonuç üretmektedir.
- Çalışma maliyeti insana nazaran hiç denecek kadar azdır.

Yukarıda başlıca avantajları belirtilen bilgisayar sisteminin tüm yönleriyle bilinen bir işi daha kısa sürede, daha az maliyetle ve her seferinde aynı kalitede yapması tercih nedeni olurken hızla gelişen tıp sektöründe bu avantajlar tersine dönebilir. Programların gelişen yöntemle adapte edilmesi ancak öncekinden farklı sonuçlar üretebilmesini sağlayacaktır. Burada programı geliştirme ve yeni programı yükleme yeni bir maliyet olacaktır. Eldeki donanımlar gelişen program için yetersiz olduğunda yenilenmesi ayrıca maliyet gerektirecektir. Bu yükseltgeme maliyetine karşın, insanlar öğrendikleri bir işi kendileri iyileştirebilmekte, geliştirebilmektedirler.

Maliyeti düşürmek için düşünebilen ve kendi konusunda kendini geliştirebilen, kendi kendine öğrenebilen akıllı bilgisayarlar gerekmektedir. Bu aslında yapay zeka konusu gibi görünse de, yapay zeka ile geliştirilen programlarında gerçekten akıllı olup olmadıkları belirsizdir. Düşünen bir bilgisayar mı? Programlanmış bir makine mi?

Amaçlanan hedef, insanların hastaneye girdikleri anda kendilerine doktorlar yerine makinelerce sorulan sorulara cevap vermeleri, bilgisayar destekli sistemin istediği örnekleri vererek tedavinin bilgisayar sistemi tarafından kararlaştırılmasıdır.

İlk olarak bu sistem hekime seçenekler sunan bir sistem olarak geliştirilmeyi amaçlanmakta, insan sağlığı söz konusu olduğu için belirli bir hata oranı altında doğru teşhisler önerdiğinde ancak sistem tamamen kullanılabilir olacaktır. Böylece muayene eden ve tedavi eden bir makine geliştirilmiş olacaktır. Teşhis masrafları azalacaktır. Yeni tedavilerin ve teşhis yöntemlerinin bulunması ve uygulanması aşamasında ve bilginin

bilgisayar ortamına aktarılmasında yine doktorlara ihtiyaç olacaktır. Ancak kendi kendine hastalığı teşhis etmeyi öğrenen, hastalığın tedavisini bulan ve uygulayan bir sistem geliştirilebilirse, hekimlerin görevleri biraz daha azalacaktır. Hastalar da şifaya daha erken kavuşacaklardır. Böylece sağlık sistemi daha güçlü hale gelecek, insanlar daha iyi şartlarda bakılacaklardır.

Bunun yanında olayın bilim kurgu filmlerine de konu olan robot–insan, yapay–gerçek zekâ çatışması, insanın tıbben zayıf yönlerini öğrenen ve buna yönelik biyolojik saldırı için silah geliştirmek için kullanılacak robotları da olası hale getirecektir. Filmlerin ne kadar gerçeği yansıttığını teknolojinin hızla ilerlemesine bakılırsa kısa süre sonra görülecektir.

Günümüzde en büyük sağlık sorunlarından biri olan kanserin kontrolünde ve önlenmesinde, hastalığın mümkün olduğunca erken teşhisi ve hangi aşamada olduğunun bilinmesi önemlidir. Patolojik doku örneklerinin bilgisayar tabanlı analizi konusunda yapılan çalışmada, hazırlanan donanımla patolojik araştırmada kullanılmak üzere mide deri gibi farklı dokulardan alınmış kanserli ve normal hücre örneği görüntüleri mikroskop, kamera ve capture (yakalama) kartı kullanılarak bilgisayara aktarılmaktadır. Hazırlanan yazılımla her bir hücrenin alanı, ortalama alan, standart sapma ve standart sapma sonrası alan hesaplanmaktadır [1].

Projede, kandaki demir eksikliğinin algılanabilmesi için “Periferik Yayma” işlemi sonucunda farklı renklendirme yöntemleriyle oluşan görüntüler üzerinde çalışılacaktır.

Bir sonraki bölümde anemi ve periferik yayma hakkında genel bir bilgi verilecektir.


1.3. Anemi

1.3.1. Anemi Tanımı

Anemi, kan hemoglobin düzeyinde veya kırmızı kan hücreleri sayısında azalma ve buna bağlı gelişen bulgulardır. Bu azalma, çoğu zaman o toplum için belirlenmiş normal sınırların altına düşmeyi ifade eder.

1.3.2. Kırmızı Kan Hücrelerinin Başlıca Görevi

Dokularımızın canlılığını sürdürebilmesi için oksijen son derece gerekli bir elementtir. Kan dolaşımımızdaki kırmızı kan hücreleri, dokulara oksijenin taşıma görevi için ideal olarak tasarlanmış olup, bünyelerinde bulundurdukları son derece özel bir protein kompleksi sayesinde bunu başarırlar. Oksijeni bağlama özelliğine sahip bu protein, hemoglobindir. Ayrıca, kana kırmızı rengini veren de hemoglobindir. 1 mm^3 kanda ortalama 5 milyon kadar kırmızı kan hücresi bulunur. 100 mL kanda ortalama hemoglobin miktarı 15 g kadardır. 1 g hemoglobin, 1.4 mL oksijen taşır. Yani, 100 mL kan ile dokulara 20 mL civarında oksijen gönderilebilir. Şekil 3'te kırmızı kan hücresinin üç boyutlu görüntüsü gösterilmektedir.



Şekil 3. Kan hücresi

1.3.3. Kırmızı Kan Hücrelerinin Yapılması

Ortalama ömürleri dört ay kadar olan kırmızı kan hücreleri, bu sürenin sonunda parçalanırlar ve yerine yenileri yapılır. Vücudun ihtiyaçlarına cevap verecek hızda devam eden bu yapım-yıkım işlemine eritropoez adı verilir.

Son derece kontrollü bir şekilde meydana gelen eritropoezde bazı doku ve organların rolü büyüktür. Böbreklerimizdeki bazı hücreler, eritropoetin adı verilen bir hormonu salgılar. Bu hormonun salgılanışı böbreklere kırmızı kan hücreleri tarafından ulaştırılan oksijen miktarı ile ters orantılıdır. Yani, gelen oksijen miktarı az ise eritropoetin salgısı artar. Eritropoetin, kemik iliğindeki ana hücrelere etki ederek, kırmızı kan hücrelerinin

yapımını başlatır. Yaşam süresini tamamlayan kırmızı kan hücreleri ve hemoglobin, retiküloendotelial sistem hücreleri tarafından parçalanır. Ortaya çıkan parçalanma ürünlerinin bazıları, tekrar kan yapımında kullanılmak üzere kemik iliğine gönderilir. Bu döngünün iyi bir şekilde işleyebilmesi için, normal böbrek fonksiyonlarına, sağlıklı bir kemik iliğine ve başta demir olmak üzere, yeterli miktarda yapı taşına ihtiyaç vardır. Bu döngüdeki herhangi bir komponentin, herhangi bir nedenle yetersizliği anemiye yol açar.

1.3.4. Hemoglobin İçin Normal Düzeyler

Kanda ölçümü yapılan maddelerin pek çoğu gibi, kırmızı kan hücreleri ve hemoglobin ile buna bağlı diğer parametrelerin ortalama normal değerleri ve normal alt sınırları, yaş, cinsiyet, hamilelik ve ırk gibi faktörlere bağlı olarak değişiklik gösterir. Ayrıca, sigara ve yaşanılan yerin, deniz seviyesinden yüksekliği de kırmızı kan hücreleri ve hemoglobinin kan düzeylerini etkiler. Bütün bu nedenlerle, hekim, laboratuvarının kullandığı yöntem ve buna göre belirlenmiş referans değerler konusunda dikkatli olmalıdır. Ölçümlerdeki olabilecek yanlışlıklar gibi, seçilen referans değerlerin, yaşanılan topluma uygun olmaması da yanlış yorum ve tedaviye neden olabilir.

Tablo1. İnsanlardaki normal kan değerleri

PARAMETRELER	ERKEK	KADIN
Hemoglobin (g/dl)	13,5-17	12-16
Hct	40 - 52	36 -48
Eritrosit (milyon/mm ³)	4,5-6	4-5,5
OEH-MCV (μ^3)	80-100	80-100
OEHb – MCH (pg)	27-34	27-34
OEHbK-MCHC (%)	31-37	31-37
Retikülosit (%)	0,5 -2	0,5 -2
Eritrosit dağılım genişliği (RDW)	8,5 -11,5	8,5-11,5
Eritrosit Ömrü (gün)	120	120

1.3.5. Anemide Görülen Belirtiler

Anemi, aslında kendisi tek başına bir hastalık olmayıp, çoğu zaman, altta yatan diğer bir rahatsızlığın objektif bir bulgusudur. Bu nedenle, bir hastanın anemisinden söz edilirken, altta yatan nedeni de içerecek şekilde söz edilmesi daha doğru olur. Örneğin; demir eksikliği anemisi, folik asit eksikliği anemisi, hemolitik anemi gibi. Anemili hastalarda görülen klinik bulgular iki ana grupta toplanabilir.

1. Dokulara oksijen taşıma kapasitesindeki azalmaya ve vücudun bu eksikliği gidermek amacıyla çalıştırdığı mekanizmalara bağlı gelişen bulgular.
2. Anemiyi doğuran asıl hastalık nedeniyle gelişen bulgular.

1.3.6. Aneminin Nedenleri

Ayrıntılı bilgi ekte verilecek olmasına rağmen başlıca nedenler aşağıda listelenmiştir [2].

- Ani veya yavaş gelişen kan kayıpları
- Kırmızı kan hücrelerinin aşırı yıkımı
- Glutatyon veya globulin sentezlerinin bozulması,
- Glikoliz veya hücre zarı bozuklukları,
- Kurşun ve diğer toksik maddelerle olan zehirlenmesi
- Enfeksiyonlar (sıtma vs.)
- Dalağın fazla çalışması
- Lenfoma
- İlaçlar
- Yetersiz kırmızı kan hücresi üretimi
- Temel maddelerin eksikliği (Demir, folik asit, B12, protein, niasin, bakır vs.)
- Eritroblast eksikliği (Aplastik anemi, kimyasal ajanlar, antikorlar vs.)
- Kemik iliğinin diğer hücreler tarafından işgali (lösemi, lenfoma, multiplmyeloma)
- Endokrin anormallikler (Miksödem, hipofiz yetmezliği, adrenal yetmezlik vs.) .
- Kronik hastalıklar (Kronik böbrek hastalığı, kollajen doku hastalıkları, siroz vs.) .

1.3.7. Anemi Türleri

Anemi sınıflaması çeşitli şekillerde yapılabilirse de sıklıkla kullanılanlardan birisi de, kırmızı kan hücrelerinin şekillerine göre yapılan sınıflamadır. Buna göre anemiler, 3 ana gruba ayrılırlar.

- Mikrositer anemi
- Demir eksikliği anemisi
- Talassemiler
- Kronik hastalık anemisi
- Sideroblastik anemi
- Normositer anemi
- Kronik hastalık anemisi
- Hemolitik anemiler
- Kemik iliğinin infiltratif hastalıkları
- Kronik böbrek hastalıkları
- Kronik karaciğer hastalıkları
- Malign hastalıklar
- Makrositer
- Kronik karaciğer hastalıkları
- Hipotroidi
- Postsplenektomi
- Vitamin B12 eksikliği
- Folik asit eksikliği

1.3.8. Anemi Tanısında Kullanılan Laboratuvar Testleri

Hematokrit: Kanın şekilli kısmının hacminin toplam kan hacmine oranıdır. % de olarak ifade edilir. Yaşa ve cinse göre değişiklik gösterir.

MCV: Kırmızı kan hücrelerinin ortalama hacmi; hematokritin kırmızı kan hücre sayısına bölümü ile hesaplanır. Kırmızı kan hücrelerinin büyüklüğü hakkında bilgi verir. Buna göre hücreler, mikrositer, normositer ve makrositer olarak gruplanır.

MCH: Kırmızı kan hücrelerinde bulunan ortalama hemoglobin miktarıdır. Hemoglobin miktarının kırmızı kan hücre sayısına bölümü ile hesaplanır.

MCHC: Ortalama bir kırmızı kan hücrelerinde bulunan hemoglobin konsantrasyonunun yüzde olarak ifadesidir. MCH ile MCHC nin farkı iyi anlaşılmalıdır. Birincisi, kırmızı kan hücresindeki hemoglobinin ağırlığıdır. İkincisi konsantrasyondur, yani birim hacimdeki ağırlıktır, g/dl olarak ifade edilir. Bu parametreler, kırmızı kan hücrelerinin içerdiği hemoglobin ve dolayısıyla rengi ile ilgili ölçütler olduğundan, hücrelerin hipokrom ve normokrom olarak sınıflamasında kullanılır.

RDW: Kırmızı kan hücrelerinin dağılım genişliğidir. Ancak gelişmiş otomatik kan sayım cihazları tarafından belirlenebilir. Kırmızı kan hücreleri de görülen anizositoz hakkında bilgi verir. Anizositoz, kırmızı kan hücrelerinin boyutlarındaki farklılığın bir ifadesidir. (Demir eksikliği anemisinde MCV düşük, RDV yüksektir. Beta talassemi minörlü bir hastada ise MCV düşükken RDV normaldir.).

HDV: Diğer bir dağılım genişliği indeksi olup kırmızı kan hücrelerindeki hemoglobin bazındaki dağılımı yani anisokromaziyi gösterir. RDV nin analogudur.

Periferik Yayma: kanın şekilli elamanlarının mikroskop altında gözle değerlendirilmesidir. Lam üzerine ince bir şekilde yayılan kan damlası, özel bazı işlemlere tabi tutularak hücrelerin boyanması sağlanır. Bu şekilde diğer kan hücrelerin yanında, kırmızı kan hücreleri de şekil, boyut ve renk olarak değerlendirilir. Bazen, kırmızı kan hücreleri, tanıda çok değeli olan özel yapılar içerebilirler. Ayrıca, az önce bahsettiğimiz hesaplamalar ortalama değerlerler olduğundan, makrositik ve mikrositik hücrelerin bir arada bulunduğu durumda, normal sonuçlar vererek yanıltabildiği için, pek çok hastalığın tanısında, kanın gözle incelenmesi vazgeçilmez bir araçtır.

Diğer Sık Kullanılan Testler: Serum demiri ve toplam demir bağlama kapasitesi, ferritin, folik asit ve vitamin B12 düzeyleri ile serbest eritrosit protoporfirindir.

1.3.9. Demir Eksikliği Anemisi

Dünyada olduğu gibi Türkiye’de de en çok görülen anemi tipi, demir eksikliği anemisidir. Önlenmesi ve tedavisi çoğunlukla kolay olan bu anemi tipinin anlaşılması için, demirin vücudumuzda ne işe yaradığını ve demirin nasıl alındığına dair bilgilerin özetlenmesi faydalıdır.

1.3.10. Demir Metabolizması

Demir vücuda çeşitli gıdaların içinde alınır. Normal şartlar içinde, günde 10 -15 mg kadar demir alınır. Ayrıca, bağırsakların iç yüzeyindeki hücrelerin dökülüp parçalanması ile ortaya çıkan demirin bir kısmı da tekrar emilerek kullanılır. Alınan bu demirin % 5-10 nu bağırsaklardan emilir. Demir eksikliği söz konusu olunca, demir emilimi bir kaç kat artabilir. Genel olarak, günlük demir alımı ile kaybı, birer mg olup dengededir. Emilen demir, kanda “transferin” adı verilen özel taşıyıcı bir protein tarafından taşınır. Normal şartlarda bu taşıyıcı molekülün 1/3 ü demir ile dolu haldedir. Transferrin demiri, kullanıldığı hücelere götürür. Demirin çoğunluğu, başta hemoglobin olmak üzere oksijen başlayan moleküllerin yapımında kullanılır. Kırmızı kan hücreleri içindeki demir, hücre yıkılana kadar içinde kalır. Yaşam sürelerini dolduran kırmızı kan hücrelerinin, başta dalak olmak üzere, retikuloendotelial sistem adı verilen özel bir dokuyu içeren organlarda yakılmasının ardından ortaya çıkan demir tekrar kan yapımında kullanılır. Bir kısım demirde, bu dokularda ferritin ve hemosiderin adı verilen moleküllerin yardımı ile depo edilir. Gerekğinde tekrar kullanılır. Ferritin suda eriyebilen bir molekül olduğu için, serumda bir miktar bulunur. Vücut demir depolarının durumunu göstermesi açısından serum ferritin düzeyi, önemli bir göstergesidir. Serum ferritin düzeyi düşüklüğü vücut demir miktarının azaldığını işaret eder. Ancak, enflamasyon, karaciğer hastalıkları ve kanser mevcudiyetinde miktarı reaktif olarak artabileceğinden, demir eksikliği gizli kalabilir.

1.3.11. Demir Eksikliğinin Ortaya Çıkış Nedenleri

Genel olarak, iki ana nedeni vardır; ya demirin vücuda alımı yetersizdir, ya da demir normalden daha hızlı kaybedilmektedir. Gelişmiş ülkelerde, diyetle demir eksikliği çok rastlanan bir problem olmazken, diğer ülkelerde önemli bir nedendir. Ayrıca, vücut ihtiyacının arttığı dönemlerde, diyetteki demirin ihtiyacı karşılamaması demir eksikliği anemisine yol açar. Hayatın ilk yılında ve ergenlik döneminin ilk yıllarında gelişim hızlıdır ve demir ihtiyacı artar. 6. - 20. Aylar arasında sadece sütle beslenen bebeklerin ek demire ihtiyacı vardır. Yaşlılık nedeniyle, yeterli beslenmeme söz konusu olduğunda, ya da bağırsakların absorbe etme kapasitesi zaafa uğradığında demir eksikliği meydana gelebilir. Geçirilen mide ameliyatları da demir emilimini etkileyebilir. Ayrıca, normal olmayan bazı

maddelerin alımı (kil, nişasta vs.) da demir emilimini etkiler. Bağırsaklardan pek çok maddenin emilimini etkileyen bazı hastalıklarda demir emiliminin de bozulmasına bağlı olarak demir eksiliği ortaya çıkar. Gebelik ve emzirme dönemi ihtiyacın arttığı dönemlerdir. Bu dönemlerde, günlük ihtiyaç, 2-5 mg'a kadar ulaşabilir. Normal diyet demiri ile bu genelde sağlanamadığından dışarıdan demir içeren ilaçların verilmesi sıklıkla gerekir. Demir eksikliği anemisi, kadınlarda erkeklere göre daha fazla rastlanır. Bunun en önemli nedeni, kadınların menstrüel dönemlerindeki kan kayıplarıdır. Adet döneminde yaklaşık 50 ml kadar kan kaybolur. Ancak bazı kadınlarda bu kayıp 5 misline kadar olabilir. Bu kadınlarda, günlük demir ihtiyacı, 3-4 mg a ulaşır. Genelde diyetle alınması pek mümkün olmayan bu miktar nedeniyle, ilave bir demir medikasyonu yapılmıyorsa, hemen daima bu kadınlarda demir eksikliği anemisi bulunur. bazı hastalıklar sürekli kan kaybına yol açarak, demirin tükenmesine neden olurlar. Bunların en çok görüleni gastrointestinal sistem kanamalarıdır. Mevcut demir eksikliği olan şahıslarda, bilinen başka bir sebep yoksa ilk araştırılması gereken sindirim sistemidir. Ülseri veya kronik gastriti olan kişilerde zaman, zaman meydana gelebilecek küçük kanamalar demir kaybına yol açar. Polip veya hemoroidler de kronik kan kaybına yol açan diğer gastroentestinal sistem problemlerindedir. Devamlı aspirin kullananlarda da, ortaya konmuş bir lezyon olmasa da kronik demir kaybına yol açabilir. Barsak enfeksiyonlarında ve parazitlerde kan kaybına neden olarak demir eksikliği anemisine yol açabilirler. Genital sistemden gelen adet dışı kanamalar, böbrek taşı veya diğer nedenlerle meydana gelen üriner sistem kanamaları da demir kaybına yol açarlar. Çok daha nadir nedenlerle, kırmızı kan hücrelerinin damar içinde veya akciğerlerde parçalanması, hemoglobinin idrarla atılmasına ve dolayısıyla demir kaybına yol açar [3].

1.3.12. Demir Eksikliği Tanısının Konulması

Laboratuar Bulguları:

- *Hemoglobin*: Sağlıklı bir Kadında, 12-16 g/dl iken Erkeklerde 13,5-17 g/dl'dir. Demir eksikliği anemisinde bu değerlerden daha düşüktür.
- *Hematokrit*: Sağlıklı bir Kadında, 36-48 iken Erkeklerde 40-52 dir. Demir eksikliği anemisinde bu değerlerden daha düşüktür.
- Ortalama Eritrosit Hemoglobin 27 den düşük bulunur.

- Serum demir düzeyi normalden düşük bulunur
- Serum ferritin düzeyinin veya kemik iliğinde sideroblastların azalmış bulunması tanıyı kesinleştirici kriterlerdir;

Periferik Yayma Bulguları:

- Hipokromi: Eritrositlerin ortasındaki boş soluk alanın 1/3 den daha büyük olmasıdır. Hemoglobinin sentez bozukluğunu gösterir.
- Mikrositoz: Eritrositlerin normalden küçük olmasıdır. MCV (MitCorpuscular Volume) (ortalama eritrosit hacmi) 80 fL'den küçük olması durumudur.
- Anizositoz: Eritrositlerin büyüklüklerinin farklı olmasıdır.
- Poikilositoz: farklı şekillerdeki eritrosit varlığını gösterir. Dizeritropoez (Kalitesiz eritrosit yapımı)'in bir belirtisidir.


1.3.13. Tedavi

Demir eksikliği anemisi çoğu kez kolaylıkla tedavi edilir. Ancak, demir eksikliğine yol açan nedenin belirlenip ortadan kaldırılması da gereklidir. Demir açığı bulunan bir kişinin alması gereken toplam demir miktarı kabaca hesaplanabilir. Toplam doz (mg)= Vücut ağırlığı x 2.3 x (15 - hastanın hemoglobini g/dl) + 500 veya 1000 (depo için) Demir eksikliği anemisinde ağız ve damar yolu ile verilen ilaçlar kullanılır. En iyi emilen demir ilacı demir sulfattır. Günlük 180 mg alındığında 10-20 mg lık bir miktar emilir. Üç bölünerek aç karna alınması faydalı olur. 3 haftalık bir tedaviden sonra, hematolojik göstergeler değişmeye başlar. Bu nedenle, tedavinin kontrolü 3 haftalık aralıklarla yapılabilir. Normal değerlere genellikle 2. Aydan sonra ulaşılır. Depoların doldurulması için, 3 - 6 ay kadar daha demir almaya devam etmek gerekir. Bazı durumlarda demir damar veya kas yolu ile verilir [4].

1.3.14. Periferik Yayma

Periferik yayma, kan hastalıkları yanı sıra enfeksiyon, karaciğer başta olmak üzere diğer sistemlerdeki bozuklukların tanısında kullanılan temel bir laboratuvar yöntemidir. Değişik hastalıkların seyri sırasında oluşabilecek morfolojik bozuklukların fark edilerek tanınmalarını kolaylaştırmak amacıyla yapılır. Yöntem kişisel değerlendirmeyi esas aldığı

için hatalı değerlendirme olasılığı her zaman söz konusudur. Bu açıdan yöntemin sınırlılıklarının, kısıtlılıklarının ve hata kaynaklarının bilinmesi ve preparatın hazırlanması aşamasında titizlik gerektirir.




Şekil 4. Periferik yayma

Şekil 4’te yapılan periferik yaymanın kalitesi değerlendirildiğinde aşağıdaki sonuçlara ulaşılmıştır [5].

1. Çok ince, kan damlası küçük.
2. Uygun.
3. Çok kısa, kan damlası küçük.
4. Çok kalın ve kan damlası büyük.

Görüldüğü üzere, bir cam üzerine ince bir şekilde yayılan kan damlası, özel bazı işlemlere tabi tutularak hücrelerin boyanması sağlanır. Bu şekilde diğer kan hücrelerin yanında, kırmızı kan hücreleri de şekil, boyut ve renk olarak değerlendirilir. Bazen, kırmızı kan hücreleri, tanıda çok değerli olan özel yapılar içerebilirler. Ayrıca, az önce ortalama değerlerler olduğundan, makrositik ve mikrositik hücrelerin bir arada bulunduğu durumda, normal sonuçlar vererek yanıltabildiği için, pek çok hastalığın tanısında, kanın gözle incelenmesi vazgeçilmez bir araçtır. İncelenecek görüntü örnekleri Şekil 5’te görülmektedir.




Şekil 5. Periferik yayma sonuçları (mikroskop görüntüleri)

Periferik yayma sırasında dikkat edilmesi gereken noktalara ve istenmeyen durumlara hakkında konunun kavranması amacıyla kısaca değinilecektir.


Önemle dikkat edilmesi gereken, daima toz ve kir içermeyen lamalar kullanılmalıdır. Yağlı lamlarda preparatın kalınlığında üniformite sağlanamaz, böylece kaliteli boyama yapılamaz.

Eritrositlerde şekil bozukluğu oluşturmamak için yaymanın hemen kurutulması uygun olacaktır. Eğer kuruma tamamlanmadan boyama yapılacak olursa mikroskobik inceleme sırasında eritrositler üzerindeki su damlacıkları, Şekil 6'da görüldüğü gibi yanlışlıkla hipokromi izlenimi verecektir. Aynı zamanda eritrosit içi paraziti eğer varsa görülemeyecektir.



Şekil 6. İyi kurutulmamış bir yaymada su partikülleri

Boyamanın aşırı olması durumunda boya partikülleri (Parçacıkları) lam üzerinde kalarak yanlışlıkla Şekil 7’de görüldüğü gibi trombosit izlenimi verebilir.



Şekil 7. Boya artıkları trombosit izlenimi veriyor

Periferik yayma sonucu görülen hücrelerden bazıları Ek1’de görülmektedir.

Periferik yayma kan hastalıkları yanı sıra enfeksiyon, karaciğer başta olmak üzere diğer sistemlerdeki bozuklukların tanısında kullanılan temel bir laboratuvar yöntemidir. Yöntem kişisel değerlendirmeyi esas aldığı için hatalı değerlendirme olasılığı her zaman söz konusudur. Bu açıdan yöntemin sınırlılıklarının, kısıtlılıklarının ve hata kaynaklarının bilinmesi ve preparatın hazırlanması aşamasında titizlik gerektirir.

İnceleme sırasında üç ana hücre grubunun (lökositler, eritrositler ve trombositler) ayrı ayrı değerlendirilmesi gerekir.

Bunlar başlıca stoplazma ve çekirdekle ilgili anomalilerin tanınması, lökositlerde alt grupların total lökosit sayısına göre oransal olarak değişip değişmedikleri, eritrositler açısından büyüklük, şekil ve hemoglobin içeriklerinin değerlendirilmesi, trombositler açısından da kümeleşme eğilimleri, büyüklükleri gibi özelliklerdir. Hücrelerin içinde inklüzyon cisimciklerinin bulunup bulunmaması, normalde periferik dolaşımda bulunmaması gereken hücrelerin varlığına dikkat edilmelidir [6].

1.4. Ön İşlemler

Görüntü işleme sistemlerinin çalışmasında kullanılan birçok işlem basamakları vardır. Bu işlem basamakları bu bölümde kısaca anlatılacaktır.

Görüntü işlemede ilk adım, görüntüyü gerçek dünyadan bir film tabakasına veya bir hafıza birimine almamızı sağlayan resim algılayıcılarıdır. Bu cihazlarda bir resim algılayıcısı ve algılanan resmi sayısal hale getiren sayısallaştırıcı birim bulunmaktadır.

Eğer resim sensörü resmi doğrudan sayısal hale dönüştürmüyorsa, elde edilen analog resim, bir Analog/Sayısal dönüştürücü yardımıyla sayısal hale dönüştürülmektedir.

Sayısal resim elde edildikten sonra ön-işleme yapılacaktır. Adı üstünde ön-işleme, sayısal resmin kullanılacağı amaca yönelik başarılı bir sonuç üretebilmek için görüntünün bazı ön işlemlerden geçirilmesidir. Bu işlemler, gürültünün azaltılması ve mümkünse yok edilmesi, görüntü üzerinde kenarların belirgin hale getirilmesi, görüntünün renk bilgisinin değiştirilmesi ve benzeri işlemlerdir.

Görüntü üzerinde ön işlemler ile bölütlenmeye hazır hale getirilmiş olur. Görüntü bölütleme, görüntüyü birbiriyle çakışmayan fakat görüntünün tümünü içeren alt imge gruplarına ayırma işlemidir. Bu gruplandırma işlemi görüntünün belirli bir veya birden fazla özelliği dikkate alınarak gerçekleştirilebilmektedir. Amaç, ilgilenilen değişik özelliklere sahip bölgelerin bir birinden ayrıştırılması veya artalanın belirlenmesi olabilmektedir. Bölütleme görüntü işlemenin en zor kısımlarından biridir. Kullanılan bölütleme tekniği sonucunda belirli bir hata oranı olabilmektedir. Karakter ve örnek (pattern) tanıma gibi oldukça karmaşık problemlerin çözümü için farklı bölütleme yöntemleri birleştirilerek kullanımı gerekebilmektedir.

Bölütleme işlemi sonrasında, görüntüden seçilen parçaların sınıflandırılması ve tanınması aşamasına sıra gelecektir. Bu aşamada, görüntü içindeki nesnelere önceden belirlenen tanımlamalara göre etiketlendirilecektir.

1.4.1. Sayısal Görüntünün Kullanılması

Gerçek görüntü insanın gözü tarafından örneklenerek algılanmasına karşı sayısal görüntü, merceğin ve merceğin bağlı olduğu sensörün özelliğine göre farklı sayı ve renklerdeki noktalar bütünüdür. Noktaların sayısı, gerçek görüntünün hangi netlikte örneklendiğine bağlıdır. Sayısal görüntüde her bir nokta belirli bir bellek alanına ihtiyaç duymaktadır. Her bir nokta için gerekli bellek alanı renk derinliğiyle doğru orantılıdır.

Siyah-Beyaz bir renk derinliğine sahip bir görüntüdeki nokta için ikili bilgi saklayabilen bir bitlik alan yeterli olurken, 256 farklı rengin gösterilebilmesi için 8 bit (1 byte) gerekmektedir. Daha gerçekçi görüntülerin oluşabilmesi için günümüzde en az 24 bitlik renk derinliği kullanılmaktadır.

Görüntü işleme sırasında ele alınacak birim eleman, sayısal görüntü üzerindeki noktalardır. Bu noktalar, bundan sonraki anlatımlarda literatürde olduğu gibi piksel (pixel:

İngilizce resim elemanları anlamına gelen “picture elements” in kısaltması) olarak bahsedilecektir.

Görüntü üzerindeki piksellerle işlem yapabilmek için, görüntü iki boyutlu bir matris ve her bir piksel bu matrisin bir elemanı olarak adreslenecektir. Matristeki elemanın (piksel) değeri ise parlaklık veya renk bilgisine karşılık gelecektir. Gerçekleştirilen işlemlerin hepsi bu matris ve ondan türetilen yeni matrisler üzerinde gerçekleştirilecektir. İşlemler boyunca görüntü, boyutları farklı matrislere farklı bilgiler de saklama amacıyla dönüşümler yapılacaktır.

Devam eden başlıkta, bir pikselin alabileceği renk değerleri hakkında bilgi verilecektir.

1.4.2. Renk Bilgisi

İnsan gözünün yapısından dolayı bütün renkler ana renkler (primary colors) olarak adlandırılan kırmızı, yeşil ve mavinin değişik yoğunluklarda birleşmesinden meydana gelmiş olarak algılanılmaktadır.

Renkleri belirli bir standarda göre tanımlamak için renk modelleri kullanılmaktadır. Çalışmada RGB renk modeli kullanıldığı için sadece RGB renk modeli hakkında bilgi verilecektir.

RGB, İngilizce kırmızı (Red), Yeşil (Green) ve mavi (Blue) kelimelerinin baş harflerinin bir araya gelmesiyle oluşmuş bir isimdir. Renklerin ifade edilişi de ismine uygun şekilde kırmızı, yeşil ve mavi renk bileşenlerin farklı oranlarda birleşmesi sonucudur.

Bir pikselin renk bilgisi RGB modelinde renk sakladığında, her bir renk bilgisi farklı bellek bölgelerinde saklanır. Örneğin, 24 bitlik bir renk bilgisi RGB biçiminde saklandığında pikselin rengini oluşturacak olan kırmızı, yeşil ve mavi yoğunluk değeri farklı 8 bitlik alanlarda saklanmaktadır. Sekiz bitlik bir alanda 2^8 (256) farklı yoğunluk değeri saklanabilecektir. Kırmızı, yeşil ve mavinin değişik yoğunluklarda saklanması ile farklı renk değerleri piksel için atanabilecektir. 24 bitlik bir renk derinliğinde 2^{24} farklı renk bilgisi saklanabilmektedir. Bu da insan gözünün algılayabileceğine yakın bir renk çözünürlüğüdür. Daha fazla renk derinliği bir görüntü için daha fazla bellek alanına ihtiyaç duyulmasına neden olacakken, insanın belli bir derinlikten sonrasını ayırt etmesi tıbben mümkün değildir.

Görüntü işleme çalışmalarında, belirli renklerin baskın olduğu şekillerin belirlenmesi için farklı renk modelleriyle tanımlanmış görüntüler üzerinde çalışılabilmektedir (insan yüzü tespitinde ten rengi vs).

Çalışmada incelenecek görüntülerin farklı renk ağırlıklarında olması nedeniyle RGB modeli tercih edilmiş ve görüntü gri renk bilgisine dönüştürülerek işlemlerden geçirilecektir. Gri tona dönüştürme yöntemi bir sonraki konuda anlatılacak, nedenleriyle detaylı olarak anlatılacaktır.

1.4.3. Gri Seviye Dönüşümü

Renkli bir sayısal resmin gri renk değerlerine sahip sayısal görüntüye çevirebilmek için, RGB biçiminde saklı olan görüntüdeki her bir noktanın R (red), G (green), B (blue) bileşenlerinin aşağıdaki denklemde görüldüğü oranlarda birleştirilmesi gerekmektedir.

$$\text{Gri nokta değeri} = 0.299 * R + 0.587 * G + 0.114 * B \quad (1)$$


Farklı üç değerden tek bir değer hesaplanmasıyla işlenecek veri azalmıştır. RGB değerine sahip görüntü üzerindeki bir pikselin gri değeri gösterebilmesi için RGB için ayrılmış olan bellek bölgelerine hesaplanan gri değer yerleştirilmektedir.

$$R = G = B = \text{Gri nokta değeri}$$

Renkli bir görüntüden elde edilen gri seviyeli görüntü iki boyutlu ve her elemanı 0 ile 255 sayıları arasında değer alan bir matristir. Sıfır değeri siyah rengi, 255 değeri de beyaz renk değerini temsil etmek üzere aradaki geçiş gri renk tonlarını 256 dilimde ifade ettiğinden griye dönüştürme işlemi olarak adlandırılmaktadır.

Üstte bahsedildiği gibi RGB bölgelerinin her birine değilse sadece birine bu gri değer aktarılacak olursa o rengin 256 farklı tonunu oluşturacaktır.

Literatürde gerçekleştirilen çalışmalarda, belirli bir rengin ağırlıkta olduğu görüntüler incelendiğinde amaca yönelik gri seviye dönüşüm ağırlıkları değiştirilebilmekte ve tercih edilen renkle gösterilebilmektedir.



Şekil 8. Gri dönüşümün farklı renk tonlarıyla gösterimi

Şekil 8’de görüldüğü gri seviye bilgisi aynı şekilde hesaplandığı halde farklı renk ağırlıklarıyla gösterildiğinde detayların gri görüntü üzerinde belirginliği görülmektedir.

Gri seviyeye indirgenen görüntü üzerinde kenar gibi belirli özelliklerin vurgulanabilmesi için gerekli teknikler bir sonraki filtre işlemleri konuda anlatılacaktır.

Gri seviye görüntü, görüntü üzerinde örneklerin (pattern) elde edilmesi için görüntünün cisimler ve arka plan olarak ayrılması gerekmektedir. Bu amaçla görüntü gri seviye görüntüyü binary (ikili) görüntüye dönüştürmek ilk çözüm gibi görülse de görüntü işleme işlemleri içinde görüntünün ikili hale getirileceği eşik değeri birçok çalışmaya konu olmuştur.

1.4.4. Eşikleme (Thresholding)

Gri seviye bir görüntüden ikili görüntü elde etmenin en kolay ve klasik yolu “0-255” değerlerinin orta noktası olan “128” değerini eşik olarak belirlemektir. Eşik değenden alt ve üst değere sahip olan pikseller “1” veya “0” değerlerini alacaklardır. Böylece görüntü iki renk ile gösterilebilecektir. Bu renkler siyah ve beyaz olarak seçilmesi genel bir yaklaşım olması nedeniyle ikili görüntüler siyah-beyaz görüntüler olarak da anılmaktadır. Görüntülerin yoğunluklarına göre eşik belirlemek gerekmektedir. Bunun için histogramlar kullanılmaktadır.

Bir görüntünün histogramı, görüntüdeki gri-seviyesi piksellerin sayısını gösteren ayrık bir fonksiyondur [7]. Histogram grafiğinin x-ekseni gri-seviyesi değerini gösterirken, y-ekseni de her bir gri-seviyesinde kaç tane pikselin olduğunu gösterecektir

Eşik değerinin, görüntüye göre belirlenmesi amacıyla geliştirilen genel görüntü işleme kütüphanesindeki, XITE [8] yöntemlerin yetersiz olduğu belirtilmektedir. Ortalama kaydırma yöntemi, görüntü histogramına doğrudan bağlı olduğu için, düzgün dağılıma sahip olmayan histogramlarda fazlaca hata yapmaktadır.

Otsu [9] tarafından tanımlanan ve kayan pencerelerle (sliding window) eşik değeri tespit eden iyi bilinen metot ile iyi sonuçlar alındığı fark edilmiştir [10]. Otsu, görüntü eşikleme için sınıflar arası piksel yoğunluğu karşıtlığını en üst seviyeye çıkaran piksel değerini eşik olarak seçmeyi amaçlamıştır.

Belirtilen yöntem aşağıdaki tanımlanmaktadır:

i : gri seviye piksel değeri,

F_i : i gri seviye değerine sahip piksel sayısı.

N : Toplam piksel sayısı,

P_i : i değerine sahip piksel olasılığı (oranı).

$P_i = F_i / N$ dir.

Görüntü C_1 ve C_2 olmak üzere iki bölgeye ayırmak istenilirse

$$W1(t) = \sum_{i=1}^t P_i$$

$$W2(t) = \sum_{i=t+1}^L P_i$$

$$C_1 = P_i / W1$$

$$C_2 = \frac{P_i}{W_2}$$


$$\mu_1 = \sum_{i=1}^t i \cdot P_i / W_1(t)$$

$$\mu_2 = \sum_{i=t+1}^L i \cdot P_i / W_2(t)$$

$$(Q_B)^2 = W_1(\mu_1 - \mu_T)^2 + W_2(\mu_2 - \mu_T)^2 \quad (2)$$

Buradaki $Q_B(t)$ değerini maksimum yapan 't' değeri optimum eşik değeridir. Birden fazla eşik değeri bulabilmek için denklemin genelleştirilmiş hali aşağıdadır [11].

$$(Q_B)^2(t_1, t_2, \dots, t_{m-1}) = \sum_{k=1}^m W_k (\mu_k^2 - \mu_T^2) \quad (3)$$



Şekil 9. Histogram ve otsu yöntemi ile hesaplanan eşik değeri

Şekilde görüntünün orijinal rengi, gri seviye görünümü ve histogramı üzerinde Otsu'nun yöntemiyle hesaplanan eşik değeri $t = 137$ kırmızı çizgiyle belirtilmektedir.

İkili bilgiye nasıl dönüştürüleceği anlatılan görüntü üzerinde kenar ve benzeri bilgileri belirgin hale getirmek için yapılacak işlemler sıradaki başlık altında anlatılacaktır.

1.4.5. Filtreleme İşlemleri

Görüntüleri gerçek dünyadan sayısal ortama aktarırken cihazların görüntüyü hatalı bir şekilde elde etmeleri ve aydınlatma gibi çevre koşulların yetersizliğinden kaynaklanan kalite kaybı görüntü işleme filtrelerinin kullanılmasıyla en aza indirgenebilmektedir.

Görüntü üzerindeki gürültüyü kaldırmak ve bazı görüntü özelliklerini artırmak için spatial filtreler kullanılmaktadır.

Mean Filtreleri: Görüntüye daha yumuşak bir bakış açısı sağlar. Komşu noktaların ortalamasını alır. 3x3 maskelerde her komşu nokta 1/9 ile çarpılarak toplanırlar.

Median Filtreler: Nonlineer filtrelerdir. Görüntüdeki tüm nokta değerleri yazılarak ortadaki değer alınır ve bu değere göre maske oluşturulur.

Enhancement Filtreler: Laplacian türü filtreleri ve fark (difference) filtreleridir. Görüntü üzerindeki detayları artırmak için kullanılırlar.

Azaltma yaparken kalitesini artırmak için ortalama, mean, median gibi ön işlemler yapılmasına antialiasing denmektedir [12].

Tüm bu filtrelerin görüntüye uygulanması, Convolution (Evrışim) işlemi ile gerçekleştirilmektedir.

1.4.6. Evrişim (Convolution) İşlemi

Evrışim, uzun yıllardır bilinen ve uygulanan bir matematiksel işlem olmakla birlikte bu işlemi tanımlamak için matematikte çok çeşitli terimler kullanılmıştır. Örneğin yığışım tümlemesi (superposition integral), tarama (scanning) tümlemesi, Duhamel tümlemesi, yuvarlatma (smoothing) tümlemesi, ağırlıklı ortalama ve Almanca' da katlama (faltung) tümlemesi bunlar arasında sayılabilir.

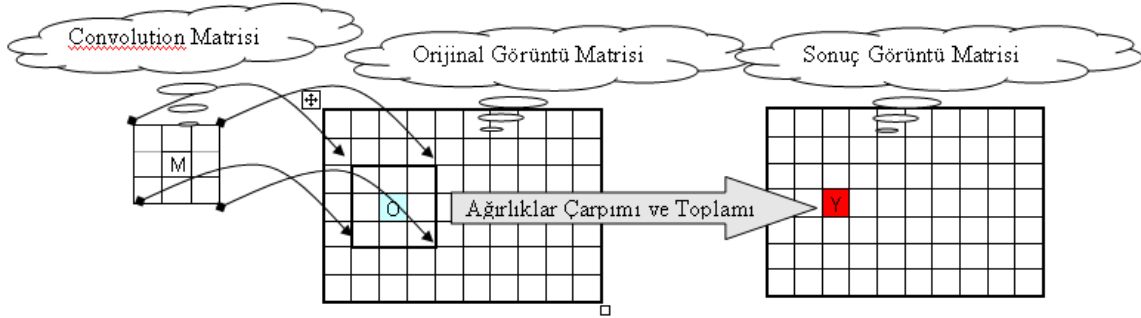
Convolution işlemi, görüntü üzerindeki her nokta değeri, komşu noktalarının farklı ağırlıktaki toplamlarıyla oluşan operasyonel (işlemsel) sonuçlar doğurur. Farklı ağırlık bilgisini taşıyan matris convolution maskesi adı verilir. Bu matrisin her bir elemanının görüntü üzerinde karşı geldiği piksel değeri ile çarpılıp toplanması ve maskenin özelliğine uygun değere bölünmesi sonucu oluşan maskelenmiş değer bellekte Orijinal görüntü üzerindeki konumuna karşılık gelecek farklı bir yere kaydedilir. Yapılan işlemlerden orijinal görüntü bilgisini tutan matris herhangi bir şekilde etkilenmez. İşlem sonucu bellekte sonuçların güncellendiği yeni matriste oluşturulmuştur.

Bu işlemin matematiksel ifadesi aşağıdaki denklemle ifade edilmektedir.

$M(r,c)$: Convolution Maskesi

$I(r,c)$: Görüntü Matrisi

$$\sum_{X=-\infty}^{\infty} \sum_{Y=-\infty}^{\infty} I(r-x, c-y)M(x, y) \quad (4)$$




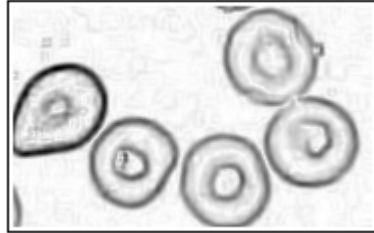
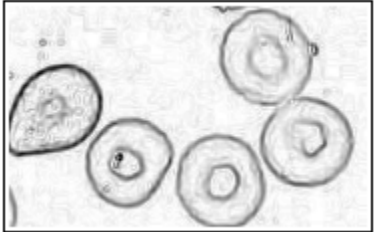
Şekil 10. Convolution işlemi şeması

Şekil 10'da Convolution işlemi şema halinde gösterilmektedir. Ağırlık değerlerini taşıyan matrisin merkezi 'M' elemanının bulunduğu yerdir.

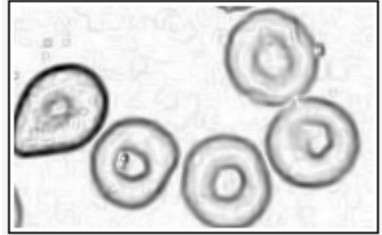
1.4.7. Kenar Güçlendirme (Algılama) Filtreleri

Kenarların güçlendirilmesi işlemi için kullanılan maskeler (filtreler) ve sonuçları aşağıdaki tabloda gösterilmektedir. Filtrelerdeki katsayılar yatay ve dikey çizgiler oluşturabilecek şekilde düzenlenmiştir.

Tablo 2. Kenar güçlendiren filtreler ve sonuçları

Yöntem	Maske Biçimi	Sonuç Görüntü
Prewitt Filtresi (3 x 3)	$\begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$ $\begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}$	
Prewitt Filtresi (5 x 5)	$\begin{bmatrix} -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \\ 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}$ $\begin{bmatrix} -1 & -1 & 0 & 1 & 1 \\ -1 & -1 & 0 & 1 & 1 \\ -1 & -1 & 0 & 1 & 1 \\ -1 & -1 & 0 & 1 & 1 \\ -1 & -1 & 0 & 1 & 1 \end{bmatrix}$	
Sobel Filtresi (3 X 3)	$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$ $\begin{bmatrix} -2 & 0 & 2 \\ -1 & 0 & 1 \\ -2 & 0 & 2 \end{bmatrix}$	

Tablo 2'nin devamı

Sobel Filtresi (5 X 5)	-1	-1	-1	-1	-1	
	-1	-1	-1	-1	-1	
	0	0	0	0	0	
	1	1	1	1	1	
	1	1	1	1	1	
	-1	-1	0	1	1	
	-1	-1	0	1	1	
	-1	-1	0	1	1	
	-1	-1	0	1	1	
	-1	-1	0	1	1	

1.4.8. Yumuşatma (Smoothing)

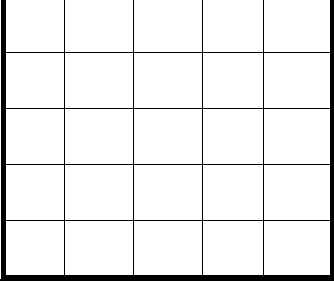
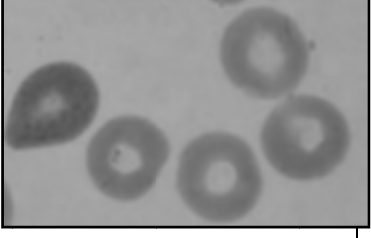
Görüntü üzerindeki detayları ve gürültüyü azaltmak için kullanılan bir yöntemdir.

Kenar güçlendirmek istenirken şekillerde görüldüğü gibi sadece hücrelerin kenarları değil ortamdaki gürültüler de belirgin hale gelmektedir. Bunu engellemek amacıyla bu tür filtreler kullanılacaktır.

1.4.8.1. Ortalama Filtresi

Bir noktayı, etrafındaki bir veya daha fazla yakınlıktaki noktaların yoğunluk değerini kullanarak belirlenen bölgenin ortalama değeri olarak güncelleyen yöntemdir. Komşu noktalardaki farklılıklar bir birine yakınsama gösterecek böylece aşırı yüksek ve aşırı düşük değerli noktalar yanlarındaki daha düşük değerli noktaların değerlerinin aritmetik ortalaması olması nedeniyle azalarak veya artarak orta bir değere geleceklerdir. Yöntem, filtre olarak Tablo 3'te görülmektedir. Kullanılan filtre boyutu ortalama ya katılacak komşuluk derecesini belirlemektedir.

Tablo 3. Ortalama filtresi sonucu


Ortalama Filtresi (5 X 5)		
-----------------------------------	---	--

1.4.8.2. Gauss Filtresi

Ortalama filtresine benzer olarak amaç görüntüdeki her noktanın kendisini çevreleyen noktaların bilgisini de kullanarak gürültülerin giderilmesidir. Burada farklı olarak filtre matrisinin (çekirdeğin) oluşturulmasında matematiksel yöntem olan Gauss dağılımı kullanılacaktır.

$$G(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \quad (5)$$


Denkelemdede (σ) dağılımın standart sapmasını göstermektedir.



Şekil 11. Bir Boyutlu Gauss Dağılımı Grafiği

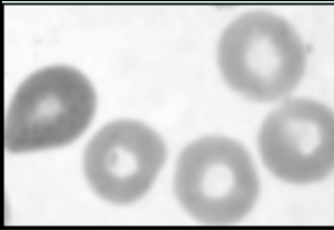
Tek boyutlu biçimi gösterilen Gauss dağılımının iki boyutlu hali nokta örtme veya nokta yayılımı fonksiyonu olarak düzleştirmeye ve gürültülerin azalmasına yardımcı olacaktır. İki boyutlu hali dairesel simetri gösteren dağılımın grafiği İki boyutlu dağılımın filtre matrisi şeklin de gösterimi ve şekle uygulanmış hali de görülmektedir. Görülen Gauss çekirdeği görüntü üzerindeki gürültüyü azaltmak için kullanılacaktır [13].

$$G(x,y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (6)$$



Şekil 12. İki boyutlu gauss dağılımı grafiği ($\sigma=1$)

Tablo 4. Gauss filtresi uygulanan görüntü

Gauss Filtresi (5 X 5)	15						
				2			
			2	5	2		
				2			

1.5. Şekil Tespiti

Eşiklenerek çevresi belirlenen hücrelerin tespitinde şekillerinin dairesel olması göz önüne alınarak, bu çevrelerden oluşabilecek çemberler tespit edilmeye çalışılmıştır. Bunun için Hough dönüşümü kullanılacaktır.

Görüntüdeki çemberleri belirleme yöntemleri on yıllar boyunca çok büyük ilgi görmüştür. Çünkü tespit edilen çember, çoğu endüstriyel uygulamadaki dairesel nesnelerin yerlerini elde etmek için kullanılabilir. Böylece birçok çember çıkartım yöntemi geliştirilmiştir [12].

Görüntü üzerinde bir şekil veya nesne aranmak istendiğinde ilk akla gelebilecek olan yöntem; örnek karşılaştırma (Pattern Matching) yöntemidir. Bu yöntemde, aranacak olan şekil örüntü üzerinde gezdirilerek eşleşme oranlarına bakılır. Eşleşme oranı istenen düzeyde olan noktaların şekli oluşturduğu kabul edilerek örüntü üzerinde işaretlenir. Bu taramada örüntüyü oluşturan her bir pixel değeri birebir karşılaştırma yapılacaktır. Rotasyon olması durumunda aranacak olan şeklin rotasyona tabi tutularak yeniden araştırılması gerekmektedir. En önemlisi sadece örnek şekil için araştırma yapılmış olacaktır. Şeklin diğer alabileceği ölçüler için (doğru araştırılıyorsa farklı eğimler, çember için farklı yarıçaplar gibi) yeni bir şekil araması yapılması gerekecek ve tüm işlemler yeniden yapılacaktır.

Geometrik olan şekillerin tespiti için yukarıdaki yöntemden daha yaygın olarak Hough dönüşümü yöntemi kullanılmaktadır.

1.5.1. Hough Dönüşümü (Hough Transform)

Hough Transformu sayısal görüntü işlemede matematiksel olarak ifade edilebilen şekillerin varlığının, yerinin, açılarının vs. bulunmasında kullanılabilir. Yöntem 1962 yılında Paul Hough tarafından bulunmuştur. IBM tarafından patentlidir.

Yöntem daha çok resimdeki doğruların tespitinde kullanılır ancak genelleştirilmiş Hough dönüşümü matematiksel olarak ifade edilebilen bütün şekillerde çalışır.

İmge üzerindeki doğrular araştırılmaya başlanmadan önce ön işlemlerden geçirilmesi gerekmektedir. Doğru oluşturabilecek kenarların resim üzerinde güçlendirilmesi için kenar algılama maskeleri kullanılır. Kenarları güçlendirilen görüntü üzerinde eşikleme yapılarak kenar bilgisi oluşturabilecek ikili bilgilerle çalışılır.

Hough dönüşümü, kenar bilgisi elde edilmiş gri-seviye imgeler üzerine uygulanır. Yöntem imge uzayındaki bilgiyi parametre uzayına taşıyarak şekil bulma problemini bir yoğunluk bulma problemine dönüştürür [13].

Örüntü üzerinde aranacak olan geometrik şeklin öncelikle parametreleri belirlenmelidir. Amaç, şekil özelliklerini belirleyebilecek olan en az parametre ile araştırma yaparak arama süresinin ve kullanılacak hafızanın en aza indirgenmesidir.

Hough dönüşümü, şekli tespit edebilmek için görüntü üzerindeki noktaların yan yana veya bağlantılı olmalarını gerektirmemektedir.

1.5.1.1. Görüntü Üzerinde Doğruların Tespiti

Matematiksel olarak bir noktadan sonsuz doğru geçmekte ve bunlarda sonsuz eğimlerde olmaktadır. Bu durumda her noktadan geçebilecek doğruların araştırılarak bunların kıyaslanması sonsuz zamana alabilecektir. Elimizdeki doğru oluşturabilecek her noktadan da sonsuz doğru geçebilecektir.

Hough Dönüşümü ile temel olarak, görüntüdeki noktalar taranarak bunlar içinde aynı doğru çizgisi üzerine düşenler araştırılacaktır. Diğer şekiller için hough dönüşümü kullanılma mantığı da yine aynı olacaktır.

Noktaların doğru oluşturması için aynı belirli özelliklere sahip olmalıdır. Bu ortak özelliklerin belirlenmesi için şeklin geometrik formülü veya yine aynı şekli belirleyecek geometrik farklı bir yaklaşımın belirlenmesi gerekmektedir.

Doğru belirleyebilmek için öncelikle doğru analitiğine değinmek gerekmektedir. Analitik olarak bir doğruyu iki şekilde tanımlamak mümkündür:

1. Bir noktası ve eğiminin bilinmesi durumunda,
2. Üzerinden geçeceği iki noktanın bilinmesi durumunda.

Görüntü üzerindeki bir noktadan geçebilecek doğruları parametreler halinde tanımlayabilmek için, ilk tanım ve bu tanıma dayalı farklı yaklaşımlar kullanılmaktadır.

$$Y = mX + b \quad (7)$$

Yukarıdaki denklemde:

m = Doğrunun eğimini,

b = Ötelenme değerini belirtmekten bir sabittir. $b=0$ olası durumunda doğru orijinden geçecektir.

$A(x,y)$ noktasından geçen, yukarıdaki denklemi sağlayan bir doğru için m ve b değerleri aynıdır. Böylece (m) ve (b) çiftleri saklanarak doğru belirginleştirilebilecektir. Bellekte saklanan (m,b) çiftleri görüntü üzerindeki doğrulara karşılık gelecektir. Görüntü alanındaki her bir (x,y) noktası, parametre uzayındaki (m,b) bilgisine karşılık gelmiş olacaktır.


Hough dönüşümü ile her bir (x,y) noktasının (m,b) uzayındaki muhtemel bir doğruya, (m,b) uzayındaki her bir nokta da görüntü uzayındaki bir doğruya karşılık gelmesi sağlanacaktır.

Hough dönüşümü, görüntü üzerindeki herhangi bir $A(x,y)$ noktasının, (m,b) uzayındaki her muhtemel doğru için bir gerçeklik değeri artırmasıyla çalışmaktadır. Bu puanlar akülerde toplanmaktadır.

Belirli bir (m,b) ikilisinin gerçeklik değeri, görüntü üzerinde bu ikilinin temsil ettiği doğruyu sağlayan noktaların sayısıdır.


1.5.2. Hough Dönüşümü Algoritması

1. Görüntü üzerindeki tüm noktalar bulunur.
2. Her bir nokta için, üzerinden geçmesi muhtemel doğruların (m,b) değerleri Denklem1 kullanılarak hesaplanır.
3. Denklemden X ve Y değerleri yerine yazıldığında (m,b) ikilisinden oluşan yeni bir iki bilinmeyenli denklemle karşılaşılacaktır. (m,b) ikililerini elde edebilmek için (m) veya (b) değerinin değişim aralığı önceden belirlenmeli (Δm veya Δb) diğeri denklem ile hesaplanmalıdır. Örneğin (m) değerinin (Δm) değişimine göre (b) değerleri bulunur. Bu değişim değeri bu noktadan geçebilecek sonsuz sayıda doğru sayısını sınırlandırmak için kullanılmıştır.
4. Bulunan (m,b) ikilisinin gerçeklik değeri bir artırılır. Böylece (m,b) ikilisini sağlayan doğrunun var olma olasılığı artmıştır.
5. Saklanan (m,b) ikililerinin yerel maksimum değeri bulunur.
6. Bulunan maksimum değeri sağlayan (m,b) ikililerinin sağladığı doğru görüntü üzerinde gösterilir (Şekil 13)



Şekil 13. İkili görüntüde tespit edilen doğruların gösterimi


Doğru tespitinde, parametre olarak, tek bir doğru belirleyebilen eğim (m) ve öteleme sabiti (b) saklanabildiği gibi, farklı ve daha iyi sonuç verecek olan görüntü üzerinde bir doğruyu oluşturacak olan noktaların, görüntü alanının her hangi bir köşesine olan dik uzaklıklarının aynı olması özelliği bilgisinden yararlanılabilir. Görüntü üzerindeki bir noktanın üzerinden geçebilecek farklı açılarda (Θ) eğime sahip doğruya, köşeden dik uzaklığı (p) parametre olarak kullanılabilir. Şekil 14'te bu parametrelerin neler olduğu gösterilmektedir.



Şekil 14. Hough dönüşümü (Θ , p) parametreleri

Bellekte (m,b) çiftlerinin gerçeklik değerleri yerine, (Θ , p) ikililerine karşılık gelen gerçeklik değerleri doğruların ortaya çıkmasını sağlayacaktır. Dönüşüm algoritmasında (m,b) parametreleri yerine yine bir $A(x,y)$ noktasından geçen tek bir doğruyu

tanımlayabilen (Θ, p) parametreleri kullanılır. Şekil 14'de görüldüğü gibi (Θ) açısının değişimi, $A(x,y)$ noktasından geçecek olan doğruyu dik olarak kesebilmesi için doğrunun eğiminin de farklı olmasını gerektirecektir. Nokta aynıyken eğimin değişmesi farklı bir doğru meydana getirecektir. Böylece (Θ, p) farklı doğruları temsil edebilecektir. Açısal değişim adımıyla $(\Delta\Theta)$ ortaya çıkan sonlu sayıda (Θ) değeri için (p) değeri, doğruların kesişim noktasının köşe noktasına uzaklığı ile hesaplanabilir. Şekil 15'te görülen $A'(c,y_1)$ noktası, $A(x,y)$ noktasından geçen ve (Θ) açısıyla köşeden gelen dik doğru parçasının kesiştiği noktadır. Köşeye olan dik uzaklık (p) , $A'(x_1,y_1)$ noktasının köşeye olan uzaklığıdır. (6)'da dik uzaklığın (p) hesaplanma şekli gösterilmiştir.




Şekil 15. (P) değerinin hesaplanması

$$P^2 = (x_1)^2 + (y_1)^2 \quad (8)$$

Köşeye olan dik uzaklığın (p) , (Θ) değerini kullanarak (9)'da görülen bağıntıyla doğrudan hesaplanması mümkündür.

$$x \cdot \cos\Theta + y \cdot \sin\Theta - p = 0 \quad (9)$$

Parametre uzayında $A(x,y)$ şeklinde olan noktayı her farklı (Θ) ye karşı gelen p şeklinde çizersek bu noktayı ifade eden bir sinüs eğrisi elde ederiz (Şekil 16).




Şekil 16. Hough sinüs eğrisi

Şekil 16'daki görüntülerin açıklaması aşağıda maddeler halinde verilmiştir.

- A) Tek bir noktanın (Θ, p) ikilileri
- B) Üç farklı noktanın (Θ, p) ikililerinin grafikleri.
- C) Görüntüdeki tüm noktaların grafiği

Bütün noktalara bu yöntem uygulanırsa eğriler bazı noktalarda kesişecektir. Bu kesişim noktaları aynı (Θ) değerine karşılık gelen aynı (p) değerleridir. Gerçekte görüntü üzerindeki farklı noktaların oluşturduğu aynı doğrulardır. (Bir doğru üzerindeki farklı noktalar). Yukarıdaki grafikte bir noktadan geçen sinüs eğrilerinin sayısının fazla olması o noktanın bir doğru ifade etmesi ihtimalini güçlendirir.



Şekil 17. (Θ, p) çiftlerini doğrulayan nokta yoğunlukları

Görüntü üzerindeki tüm noktaların tamamlanması sonucunda (Θ, p) uzayındaki yoğunluğun grafiği Şekil 17'de gösterilmektedir. Şekilde görülen tepeler aranan şekli

(doğrunun) işaret eden parametrik değerleri ifade etmektedir. Tek bir doğrunun aranması durumunda en yüksek tepiyi sağlayan parametreler doğruyu gösterecektir. Birden fazla doğru araştırılıyorsa bu değerler üzerinde bir eşikleme yapılır. Eşik değerinin gereğinden düşük seçilmesi durumunda, görüntü üzerindeki bazı gürültüler doğru olarak tespit edilecektir. Eşik değrinin yüksek seçilmesi durumunda ise görüntü üzerindeki bazı doğrular tespit edilemeyecektir.

1.5.3. Çember Tespiti (CHT)


Circle hough transform (CTH), yarıçapı belirli olan çemberleri tespit etmek için kullanılan en iyi bilenen yöntemdir [14]. Hough dönüşümünün temel kavramı görüntü ve parametre uzayını haritalandırarak eşleşme şeklini belirlemektir. Eşleşme şeklini belirlemek için, şekli temsil edecek parametrelerinin neler olacağı belirlenmelidir. Belirli bir yarıçapa sahip çemberler merkezleri olan $O(x,y)$ noktalarıyla ifade edilebilirler.

Görüntüdeki çemberin üzerindeki her bir nokta “Çemberin üzerindeysen, merkezim bunlardan biri olmalı” diyecektir. Görüntü üzerinde çemberi oluşturan diğer noktalar da aynı merkez noktası hakkında bu fikre sahip olacağından, doğruların tespitinde olduğu gibi Çemberin tespitinde de bellekteki merkez noktaların gerçeklik değerleri, bu merkeze ait bilinen yarıçapta bir çemberin görüntü üzerinde olduğunu doğrulayacaktır.

Araştırılacak olan çemberler bilinmeyen boyutlardaysa, çember yarıçapına da parametre olarak ihtiyacımız olacaktır. Böylece çemberler, (x,y,r) şeklinde parametrik hale getirilmiş olunacaktır.

$$(x-x_1)^2+(y-y_1)^2=r^2 \quad (10)$$


Görüntü üzerindeki bir noktanın, hangi çemberin kenarında olabileceğini araştırılmasında (10)'da görülen çember denklemi kullanılmaktadır. $O(x_1,y_1)$ merkezli çemberin kenar noktalarını veren denklemdir. Bir çemberin kenarını çizebilmek için belirli bir çözünürlük belirlenmelidir. Aksi takdirde iki sayı arasında sonsuz sayıda aralık oluşturulabileceğinden dolayı çizim ve tespit işlemi fazla zaman alacaktır.



Şekil 18. CHT çember araştırması

Şekil 18'de görüntü üzerindeki bir $A(x,y)$ noktasının (kırmızı ok ile gösterilen noktanın) bir çembere aitliğinin araştırılması sırasında 180 derecelik bir tarama anı gösterilmektedir. Soluk renkli çemberler noktanın üzerinde bulunabileceği (r) yarıçaplı çemberlerdir. Koyu renkli çember, noktanın etrafında çizilen (r) yarıçapına sahip çemberdir. Dikkat edilirse soluk renkli çemberlerin merkez noktaları, koyu renkli çemberin üzerinde olacaklardır.

Çember tespitinde merkez noktalarının ($O(x,y)$) saklanarak, gerçeklik değerlerinin artırılacağından bahsedilmişti. Çembere aitliği araştırılan $A(x,y)$ noktasının çevresindeki noktalar ($\check{C}(x,y)$), bu noktanın çevresinde bulunabileceği çemberlerin merkez noktalarını gösterecektir. Bellekte saklanarak gerçeklik değeri artırılacak olan noktalar da bu çevre noktaları olacaktır.



Şekil 19. Çember çevresi hesaplama

Görüntü üzerindeki bir nokta ele alındığında çevresindeki noktaların koordinatlarının nasıl hesaplanacağı Şekil 19’da gösterilmiştir.

$A(x,y)$: Görüntü üzerinde ele alınan ve çevre noktalarının koordinatları hesaplanacak olan nokta.

$\mathcal{C}(x_1,y_1)$: Araştırılan nokta.

r : yarıçap.

$$\Delta x = |x - x_1|$$

$$\Delta y = |y - y_1| \quad (11)$$


Θ : Çevre noktanın çember üzerinde hangi açıda yerleşmiş bulunduğunu göstermektedir.

Şekil 19’da görülen üçgen bir dik üçgen olduğu için farklı açılar için çevre noktalarının koordinatları, (12) ile hesaplanabilmektedir.

$$\Delta x = r \cdot \cos(\Theta)$$

$$\Delta y = r \cdot \sin(\Theta) \quad (12)$$

Bu noktada dikkat edilmesi gereken, çevre noktaları hesaplanırken kullanılacak olan açısal değişimdir ($\Delta\Theta$). Aralığın geniş seçilmesi durumunda görüntüde tespit edilmesi gereken çemberler atlanabilmektedir. Aralık azaldıkça hesaplama miktarı ve kullanılması gereken bellek boyutu artacaktır.




Şekil 20. Farklı (Θ) açılarıyla yapılan çember taramaları

Görüntü üzerindeki $A(x,y)$ noktasının ait olması muhtemel çemberler Şekil 20’de $\Delta\Theta=30^\circ$ ve $\Delta\Theta=10^\circ$ değerleri için gösterilmektedir. Daha küçük ($\Delta\Theta$) değerleri kullanılması durumunda, küçük yarıçaplar için hesaplanan çevre noktaları çakışabilmekte,

bu da bellekte artırılan gerçeklik değerlerinin anlamsızca artırmaktadır. Aynı kenar noktası birkaç bellekteki (Θ, r) ikilisinin gerçeklik değerini artırabilmektedir.

Görüntü üzerindeki her bir nokta için kenar olabileceği çember merkezleri belirlendikten sonra yoğunluğu en yüksek çember tespit edilmiş olunur. Şekil 21'de ikili bir görüntüye uygulanan CHT sonucu elde edilen sonuçlar gösterilmektedir. Görüntüdeki dört farklı çember tespit edilmiştir.



Şekil 22. CHT uygulama sonucu

Bulunan çemberler ikili görüntünün elde edildiği orijinal görüntü üzerinde gösterildiğinde Şekil 22'deki görüntü ortaya çıkmaktadır.




Şekil 22. Tespit edilen çemberlerin orijinal görüntü üzerinde tespiti

Orijinal görüntüden, çemberlerin tespit edileceği görüntünün elde edilme işlemi daha önceki bölümlerde (Bkz. Kenar belirleme, eşikleme, inceltme) detaylı olarak anlatılmıştı.

1.5.4. Eğim Vektör Çiftleri Kullanılarak Çember Tespiti

Bu yöntemde çember üzerinde eğim bilgilerinden yararlanarak, görüntü üzerindeki çemberler tespit edilecektir. Çember tespiti için yapılması gereken işlemler dört adımda toparlanacaktır.

İlk adımda görüntünün eğimi hesaplanacaktır. Çemberin eğim vektörleri şekilde gösterilmiştir. Vektörlerin yönü çemberin merkezinden dışa doğrudur. Çember üzerindeki noktaların merkez noktasına göre simetri özelliği vardır. Bu bilgi her vektörün kendine zıt başka bir vektörü olduğunu göstermektedir.



Şekil 23. Eğim vektörleri arası açı bilgileri

V_1 ve onun zıt yönlü eş vektörü V_2 şu durumları sağlamalıdır:

1. V_1 ve V_2 arasındaki açı 180° ye yakın olmalıdır. Burada çok küçük (ϵ) hata miktarı kabul edilebilir.
2. β açısı, P_1 ve P_2 noktalarını birleştiren doğruyla V_1 arasındaki açı sıfır dereceye yakın olmalıdır. (P_1P_2 ve V_1 vektörü aynı yönlü olmalıdır.)

İkinci adımda, Görüntünün eğim uzayındaki tüm vektör çiftleri, yukarıdaki durumlar kontrol edilerek bulunur. Özellikle yukarıdaki 2. durum ile hatırı sayılır şekilde kullanışsız vektörler filtrelenerek görüntü azaltılmış olunur.

Çift eşleştirme işlemini daha hızlı hale getirebilmek için, vektörleri içeren dizi vektörlerin yönlerine göre sıralanabilir. Böylece belirli bir vektörün zıt vektörü kolayca bulunabilir.

Üçüncü adımda, aday bir çember, her bir vektör çifti için dikkate alınır. P_1 ve P_2 noktalarının orta noktası merkezi olan çemberin ve aradaki mesafenin yarısı yarıçapı olacaktır. Bu yarıçap, aranan çemberin yarıçapından (belirlenen yarıçap aralığından) farklıysa, vektör çifti elenerek filtreleme yapılır. Yarıçap değişim aralığı bilinmesi durumunda yöntemin performansı artacaktır.

Dördüncü ve son adımda ise, bir önceki adımda belirlenen olası çemberler arasından istenen çemberler belirlenir. Bunun için iki yöntem kullanılabilir:

1. Üç boyutlu bir matris kullanılarak belirlenen çemberlerin oluşum miktarları saklanır. Böylece istenen çemberler yerel maksimumlar araştırılarak hesaplanır. Bu yaklaşım klasik CHT'a benzemektedir.
2. Aday çemberler bilinirken ikinci ve daha kolay bir yol doğru çemberin bulunması için kullanılabilir. Aday çemberler, (x,y,r) olmak üzere üçlü bilgiler halinde saklar ve bu üçlü bilgiler euclidean mesafesine göre gruplandırılabilir.

Çembersel bölgeler tespit edilmesine rağmen bitişik hücrelerin ayrıştırılabilmesi için bölütleme teknikleri denenmesi gerekebilmektedir.

1.6. Bölütleme

Görüntü analizindeki en karmaşık ve önemli adım görüntü bölütlemedir. Yapılacak analizin başarılı olup olmaması bölütlemenin başarısına bağlıdır. Bir görüntüyü oluşturan nesnelere ayırma işlemi görüntü Bölütleme olarak adlandırılır [15].

Başka bir tanımla ile görüntü bölütleme, homojen bir küme içerisinde aynı karakteristiğe sahip alanların çıkarılması, arka plandan ayrıştırılması, daha belirgin bir hale getirilmesi işlemleri olarak da tanımlanır. Görüntü bölütleme, öz nitelik çıkarımı ve nesne tanımanın başarısını doğrudan etkilediği için görüntü anlama sistemleri üzerinde önemli bir etkiye sahiptir [16].

İme bölütleme algoritmaları, bilgisayar görmesi uygulamalarında genellikle ilk işlem basamağı olarak kullanılmaktadır. Burada, bir grup piksel ile temsil edilen imge ögesi, imgenin bütününden ayırt edilir.


1.6.1. Watershed Dönüşümü

Watershed yöntemi, yağmur damlalarının düşmesi ve batırma düşüncesinden hareketle, örüntü eğimi arasındaki bağı alanların ayrılmasını sağlar. Orijinal örüntünün morfolojik eğimini topografik yüzey gibi ele alarak her seviyedeki komşu noktaların eğim benzerliklerini kullanarak havzalara ayrılmasını sağlar. Watershed dönüşümünü farklı şekillerde tanımlamak mümkündür. Burada tanımdan çok uygulama önemli görülmüş ve uygulamalar üzerine durulacaktır.

Havzaların, minimumların etki alanlarına karşılık geldiği anlaşılmaktadır. Bu nedenle, etki alanlarının jeodezik iskeletiyle watershedler arasında yakın bir ilişki vardır.


1.6.1.1. Watershed Dönüşüm Yöntemleri

Konunun iyi anlaşılabilmesi için öncelikle örüntü değil sıradağların oluşturduğu topografik bir yapı göz önüne alınmalıdır.



Şekil 24. Watershed topografik görünümü

Şekil 24'te sıra dağlar arasında kalan bölgeler görülmektedir. Şekilde görülen dağların dikey kesit izdüşümüdür. Asıl görüntü üç boyutludur. Şekil 25'te görüldüğü gibi üç bölgeye (havzaya) ayrılmıştır. Watershed yöntemiyle bulunmaya çalışılan üç boyutlu şeklin havzalarıdır. Bölgeler dipten su alan bir vadinin nasıl su ile kaplanacağı düşünülerek ayrılmıştır. Farklı bölgelerden taşan suların arasında setler çekileceği düşünüldüğünde şekilde görülen farklı bölgeler oluşacaktır.




Şekil 25. Watershed ile ayrılmış bölgeler

Bölgelerin ayrılması için düşünülen diğer bir yöntem ise yağmur damlacıklarının düşme ve havzalarda bir araya gelmesiyle açıklanmaktadır. Herhangi bir yere düşen bir yağmur damlası en yakın dibe akmaya başlayacak en dibe ulaştığında ancak durabilecektir. Burada damlacıkların akarken azalmayacağı (buharlaşmayacağı) ve doğrudan havzaya katılacağı varsayılmaktadır. Bu şekilde aynen batmada olduğu gibi çukurlar dolacak ve daha sonra çukurlardan taşan ve birleşen suların arasına set (watershed) çekilerek birleşmesi engellenecektir. Bu şekilde tüm alanın suyla dolmasıyla oluşan sınır çizgileri farklı havzaları ayırt etmemizi sağlayacaktır. Şekil 25'te görülen A,B ve C bölgeleri bu şekilde oluşturulmuştur.

Gerçekte, şekildeki gibi pürüzsüz eğimi olan bir yer yüzeyi ve görüntü olamamaktadır. Yüzey üzerinde gürültü veya istenmeyen küçük çukurlar da bulunabilmektedir.

Şekil 26'da yüzeydeki çıkıntılar nedeniyle oluşan küçük çukurlar ve bunlar nedeniyle oluşabilecek 'X' bölgeleri görülmektedir. Gürültü nedeniyle fazlaca bölgelerin oluşması aşırı bölütleme olarak adlandırılır. Aşırı bölütlemeyi engellemek için yüzeyin gürültülerden arındırılması veya watershed yöntemi için belirli derinlik değerlerinin gözardı edilmesi gerekmektedir.




Şekil 26. Gürültülü yüzey ve aşırı bölütleme

1.6.1.2. Görüntü Üzerinde Watershed Uygulaması

Topografik olarak bu şekilde açıklanan yöntemin, görüntü üzerinde kullanılması için görüntünün gri seviyeye dönüştürülmüş olması gerekmektedir. Gri seviyeye renk derinliğini, topografik ortamdaki yüksekliğe dönüştürdüğümüzde MATLAB programı ile karşımıza şekildeki gibi bir görüntü çıkmaktadır. Böylece Resim topografik bir yüzey olarak değerlendirilebilecektir.

Bölgelere ayrılmış olan görüntü içinden hücrelerin seçilmesi işlemi daha önceki bölümlerde anlatılmıştır. Bu yöntemin kullanım amacı bitişik hücrelerin ayrımını yapabilmesidir.

Aynen doğadaki sınır çizgilerinin bulunmasında olduğu gibi burada da amaç, çukurları dolduran su sınırlarını bulmak olacaktır. Örnek görüntüde resim üzerinde görüntüler de olduğu için çok fazla girinti çıkıntı görülmektedir. Görüntü üzerinde Watershed uygulandığında alınacak sonuç aşağıda görüldüğü gibi aşırı bölütleme olacaktır.



Şekil 27. Watershed yöntemi ile aşırı bölütlenmiş bir görüntü

Ayrık olarak elde edilen hücrelerin tanıma süreci devam eden konuda anlatılacaktır.

1.7. Yapay Sinir Ağları (YSA) ile Tanıma

YSA, beyindeki sinirlerin çalışmasını taklit ederek sistemlere öğrenme, genelleme yapma, hatırlama gibi yetenekler kazandırmayı amaçlayan bilgi işleme sistemidir.

İnsan beyninin ve düşünme yeteneğinin taklit edilmesi isteği sanıldığı gibi aksine çok eski zamanlarda var olmuş bir istektir. İnsan beyni ve düşünebilme yeteneğine ilişkin ilk açıklayıcı teori geliştirme denemeleri Antik Yunan düşünürleri olan Plato (İ.Ö. 427-327) ve Aristoteles'e (İ.Ö. 384-322) kadar uzanmaktadır. Daha sonra ise Descartes (1596-1650) insanın düşünme yeteneğiyle ilgilenen 18. yüzyıl düşünürü olmuştur.

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, Yapay Sinir Ağları denen günümüz bilgisayarlarının algoritmik hesaplama yöntemlerinden farklı bir bilim alanı ortaya çıkmıştır.

Genel anlamda YSA, beynin bir işlevini yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir. Bir YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasında oluşur. YSA'lar öğrenme algoritmaları ile öğrenme sürecinden geçtikten sonra, bilgiyi toplama, hücreler arasındaki bağlantı aşırılıkları ile bu bilgiyi saklama ve genelleme yeteneğine sahip olurlar.

YSA'lar yapılarına göre farklı öğrenme yaklaşımları kullanırlar. Yapay sinir ağlarının dayandığı ilk hesaplama modelinin temelleri 1940'ların başında araştırmalarına başlayan W.S. McCulloch ve W.A. Pitts'in, 1943 yılında yayınladıkları bir makaleyle atılmıştır. Daha sonra 1954 yılında B.G. Farley ve W.A. Clark tarafından bir ağ içerisinde uyarılara tepki veren, uyarılara adapte olabilen model oluşturulmuştur. 1960 yılı ise ilk neural bilgisayarın ortaya çıkış yılıdır. 1963 yılında basit modellerin ilk eksiklikleri fark edilmiş, ancak başarılı sonuçların alınması 1970 ve 1980'lerde termodinamikteki teorik yapıların doğrusal olmayan ağların geliştirilmesinde kullanılmasına 10 kadar gecikmiştir. 1985 yapay sinir ağlarının oldukça tanındığı, yoğun araştırmaların başladığı yıl olmuştur [17].

Günümüze kadar sayısız çalışma ve uygulama geliştirilmiştir. Bunlar:

- 1890- İnsan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması,
- 1911- İnsan beyninin sinir hücrelerinden oluştuğu fikrinin benimsenmesi,

- 1943- Yapay sinir hücrelerine dayanan hesaplama teorisinin ortaya atılması ve eşik değerli mantıksal devrelerin geliştirilmesi,
- 1949- Öğrenme prosedürünün bilgisayarlar tarafından gerçekleştirilecek şekilde geliştirilmesi,
- 1956 - 1962 ADALINE ve Widrow - Hoff öğrenme algoritmasının geliştirilmesi,
- 1957 - 1962 Perceptron'un geliştirilmesi,
- 1965- İlk makina öğrenmesi kitabının yayınlanması,
- 1967-1969 Bazı gelişmiş öğrenme algoritmalarının geliştirilmesi, (Grasberg.)
- 1969- Tek katmanlı algılayıcıların yetersizliklerinin ispatlanması,
- 1969 - 1972 doğrusal ilişkilendiricilerin geliştirilmesi,
- 1972- Korelasyon matris belleğinin geliştirilmesi,
- 1974- Geriye yayılım modelinin geliştirilmesi,
- 1978- ART modelinin geliştirilmesi,
- 1982- çok katmanlı algılayıcıların geliştirilmesi,
- 1984- Boltzman Makinası'nın geliştirilmesi,
- 1988- RBF modelinin geliştirilmesi,
- 1991- GRNN modelinin geliştirilmesi [18].

1.7.1. Literatürdeki YSA Tanımları

Yapay sinir ağının genel bir tanımı yapılması gerekirse, Yapay Sinir Ağı, insan beyninin çalışma ve düşünebilme yeteneğinden yola çıkılarak oluşturulmuş bir bilgi işlem teknolojisidir. Yapay sinir ağının işleyiş özelliklerine dayanan ikinci tür tanımı ise ilk ticari yapay sinir ağının geliştiricisi olan Dr. Robert HECHT-NIELSEN'e ait bir tanımdır: "Yapay sinir ağı dışarıdan gelen girdilere dinamik olarak yanıt oluşturma yoluyla bilgi işleyen, birbiriyle bağlantılı basit elemanlardan oluşan bilgi işlem sistemidir [19]. Bu tanıma yakın bir tanımda yapay sinir ağı yazınında çok tanınan Teuvo KOHONEN'e ait bir tanımdır". Yapay sinir ağları paralel olarak bağlantılı ve çok sayıdaki basit elemanın, gerçek dünyanın nesnelere biyolojik sinir sisteminin benzeri yolla etkileşim kuran olan, hiyerarşik bir organizasyonudur.

1.7.2. YSA'nın Uygulama Alanları

Son yıllarda YSA'ları, özellikle günümüze kadar çözümünü güç ve karmaşık olan ya da ekonomik olmayan çok farklı alanlardaki problemlerin çözümüne uygulanmış ve genellikle başarılı sonuçlar alınabilmiştir. Yapay sinir ağları aşağıdaki özellikleri gösteren alanlarda kullanıma uygun bir araçtır:

- Çok değişkenli problem uzayı,
- Probleme ilişkin değişkenler arasında karmaşık etkileşim,
- Çözüm uzayının bulunmaması, tek bir çözümün olması veya çok sayıda çözüm bulunması.

YSA'lar insan beyninin fonksiyonel özelliklerine benzer şekilde aşağıdaki konularda başarılı bir şekilde uygulanmaktadır:

- | | |
|------------------|---------------------|
| • Öğrenme | • Tahmin |
| • İlişkilendirme | • Özellik Belirleme |
| • Sınıflandırma | • Optimizasyon |
| • Genelleme | |

1.7.3. YSA'nın Avantajları

Yapay sinir ağları modelleri, biyolojik sinir ağlarının çalışma biçimlerinden esinlenerek ortaya çıkarılmıştır. Yapay sinir ağları, biyolojik olmayan yapı taşlarının düzgün bir tasarımla birbirlerine yoğun olarak bağlanmalarından oluşmaktadırlar. Sinir sisteminin modellenmesi için yapılan çalışmalar sonucu oluşturulan yapay sinir ağları, biyolojik sinir sisteminin üstünlüklerine de sahiptir. Bu üstünlükleri şu şekillerde özetleyebilmek mümkündür.

Yapay sinir ağı özellikle doğrusal olmayan sistemlerde öngörüler açısından istatistik tekniklere göre daha kolaylık sağlayan bir özelliğe sahiptir. Bundan dolayı başta işletmecilik ve finans olmak üzere birçok değişik alanlarda kullanım imkânı bulur.

Doğrusal Olmama: YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.

Paralellik: Alışılmış bilgi işlem yöntemlerinin çoğu seri işlemlerden oluşmaktadır. Bu da hız ve güvenilirlik sorunlarını beraberinde getirmektedir. Seri bir işlem gerçekleşirken herhangi bir birimin yavaş oluşu tüm sistemi doğruca yavaşlatırken, paralel bir sistemde yavaş bir birimin etkisi çok azdır. Nitekim seri bir bilgisayarın bir işlem elemanı beyine göre binlerce kez daha hızlı işlemesine rağmen, beynin toplam işlem hızı seri çalışan bir bilgisayara göre kıyaslanamayacak kadar yüksektir.

Gerçeklenme Kolaylığı: Yapay sinir ağlarında basit işlemler gerçekleyen türden hücrelerden oluşması ve bağlantıların düzgün olması, ağların gerçekleşmesi ki açısından büyük kolaylık olmasını sağlamaktadır.

Yerel Bilgi İşleme: Yapay sinir ağlarında her bir işlem birimi, çözülecek problemin tümü ile ilgilenmek yerine, sadece problemin gerekli parçası ile ilgilenmektedir ve problemin bir parçası işlemektedir. Hücrelerin çok basit işlem yapmalarına rağmen, sağlanan görev paylaşımı sayesinde, çok karmaşık problemler çözülebilmektedir.

Hata Toleransı: Sayısal bir bilgisayarda, herhangi bir işlem elemanını yerinden almak, onu etkisiz bir makineye dönüştürmektedir. Ancak yapay sinir ağlarında bir elemanda meydana gelebilecek hasar çok büyük önem teşkil etmez. Yapay sinir ağlarının paralel çalışması hız avantajı ile birlikte yüksek hata sağlamaktadır. Seri bilgi işlem yapan bir sistemde herhangi bir birimin hatalı çalışması, hatta bozulmuş olması tüm sistemin hatalı çalışmasına veya bozulmasına sebep olacaktır. Paralel bilgi işleme yapan bir sistemde ise, sistemin ayrı ayrı işlem elemanlarında meydana gelecek olan hatalı çalışma veya hasar, sistemin performansında keskin bir düşüşe yol açmadan, performansın sadece hata birimlerinin bir oranınca düşmesine sebep olur. YSA, çok sayıda hücrenin çeşitli şekillerde başlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağıın sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA' nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağıın doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

Öğrenilebilirlik: Alışılmış veri işleme yöntemlerinin çoğu programlama yolu ile hesaplamaya dayanmaktadır. Bu yöntemler ile, tam tanımlı olmayan bu problemin çözümü yapılamaz. Bunun yanında, herhangi bir problemin çözümü için probleme yönelik bir algoritmanın geliştirilmesi gerekmektedir. Yapay sinir ağları problemleri verilen örneklerle çözer. Çözülecek problemler için yapı ayıdır. YSA'nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru

bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. YSA'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemden aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

Genelleme: YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakterleri verebilir yada bir sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir. Uyarlanabilirlik: YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

Donanım ve Hız: YSA, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir.

Analiz ve Tasarım Kolaylığı: YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli, ileride açıklanacağı gibi bütün YSA yapılarında yaklaşık aynıdır.

Dolayısıyla, YSA'nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'ları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirecektir.

1.7.4. YSA'nın Dezavantajları

Donanım bağımlıdır. YSA'ların en önemli sorunu donanım bağımlı olmalarıdır. YSA'ların en önemli özellikleri ve var oluş nedenlerinden birisi olan paralel işlem yapabilme yeteneği, paralel çalışan işlemciler ile performans gösterir.

Uygun ağ yapısının belirlenmesinde belli bir kural yoktur. YSA'larda probleme uygun ağ yapısının belirlenmesi için geliştirilmiş bir kural yoktur. Uygun ağ yapısı deneyim ve deneme yanılma yolu ile belirlenmektedir.

Ağın parametre değerlerinin belirlenmesinde belli bir kural yoktur. YSA'larda öğrenme katsayısı, hücre sayısı, katman sayısı gibi parametrelerin belirlenmesinde belirli

bir kural yoktur. Bu değerlerin belirlenmesi için belirli bir standart olmamakla birlikte her problem için farklı bir yaklaşım söz konusu olabilmektedir.

Öğrenilecek problemin ağa gösterimi önemli bir problemdir. YSA'lar nümerik bilgiler ile çalışabilmektedirler. Problemler YSA'lara tanıtılmadan önce nümerik değerlere çevrilmek zorundadırlar. Burada belirlenecek gösterim mekanizması ağın performansını doğrudan etkileyecektir. Bu da kullanıcının yeteneğine bağlıdır.

Ağın eğitiminin ne zaman bitirilmesi gerektiğine ilişkin belli bir yöntem yoktur. Ağın örnekler üzerindeki hatasının belirli bir değer altına indirilmesi eğitimin tamamlandığı anlamına gelmektedir. Burada optimum neticeler veren bir mekanizma henüz yoktur ve YSA ile ilgili araştırmaların önemli bir kolunu oluşturmaktadır.

Ağın davranışlarının açıklanamamaktadır. Bu sorun YSA'ların en önemli sorunudur. YSA bir probleme çözüm ürettiği zaman, bunun neden ve nasıl olduğuna ilişkin bir ipucu vermez. Bu durum ağa olan güveni azaltıcı bir unsurdur.

Geleneksel algoritmalarla yapay sinir ağlarını karşılaştıracak olursak aşağıdaki tablo karşımıza çıkacaktır.

Tablo 5. Geleneksel algoritmalar ile YSA'ların kıyaslanması


Geleneksel Algoritmalar	Yapay Sinir Ağları
<ul style="list-style-type: none"> Çıktılar, koyulan kurallara girişlerin uygulanması ile elde edilir. 	<ul style="list-style-type: none"> Öğrenme esnasında giriş çıkış bilgileri verilerek, kurallar koyulur.
<ul style="list-style-type: none"> Hesaplama; merkezi, eş zamanlı ve ardışıldır. 	<ul style="list-style-type: none"> Hesaplama; toplu, eş zamansız ve öğrenmeden sonra paraleldir.
<ul style="list-style-type: none"> Bellek paketlenmiş ve hazır bilgi depolanmıştır. 	<ul style="list-style-type: none"> Bellek ayrılmış ve ağa yayılmıştır. Dâhilidir.
<ul style="list-style-type: none"> Hata toleransı yoktur. 	<ul style="list-style-type: none"> Hata toleransı vardır.
<ul style="list-style-type: none"> Nispeten hızlıdır. 	<ul style="list-style-type: none"> Yavaş ve donanıma bağımlıdır.
<ul style="list-style-type: none"> Bilgiler ve algoritmalar kesindir. 	<ul style="list-style-type: none"> Deneyimden yararlanır.

1.7.5. YSA Yapısı

YSA'ların yapısının daha iyi kavranması için öncelikle, taklit ettikleri insan beyninin ve onun en küçük yapı taşı olan biyolojik sinir hücresinin yapısının basitçe kavranmasında yarar vardır.

1.7.6. Biyolojik Sinir Sistemi

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beyin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem olarak açıklanır. Alıcı sinirler (receptor) organizma içerisinden ya da dış ortamlardan algıladıkları uyarıları, beyne bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri (effector) ise, beyinin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür. Şekil 28'de bir sinir sisteminin blok gösterimi verilmiştir.




Şekil 28. Biyolojik sinir sisteminin blok gösterimi

Merkezi sinir ağında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler üretilir. Bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sisteminin karakteristiklerini taşır. Merkezi sinir sisteminin temel işlem elemanı, sinir hücresidir (nöron) ve insan beyinde yaklaşık 10 milyar sinir hücresi olduğu tahmin edilmektedir.

1.7.7. Sinir Hücresi (Nöron)

Sinir hücresi; hücre gövdesi, dendriteler ve axonlar olmak üzere üç bileşenden meydana gelir.

- *Hücre Gövdesi (Soma)*: Bir nöronun gövdesine soma adı verilir. Soma nucleus adı verilen hücre çekirdeğini içermektedir. Hücrenin yaşamasını sağlayan işlevleri görür. Synapslar aracılığıyla dentriteslere geçirilen iletiler birleşerek axon üzerinde elektriksel bir çıktı oluştururlar. Bu çıktının olup olmayacağı veya çıktının elektriksel olarak yoğunluğu, synapsların etkileri sonucu hücreye gelen tüm girdilerin, toplam değeri tarafından belirlenmektedir. Somaya gelen girdilerin ağırlıklı toplamı axon üzerinde çıktı oluşuracak değere ulaştığında, bu değere “eşik değeri” adı verilmektedir ve nöron ateşlendi (fired) olarak ifade edilmektedir. Bu şekilde girdiler nöron tarafından değerlendirilerek çıktıya dönüştürülmüş olur.
- *Dendriteler*, diğer hücrelerden aldığı bilgileri hücre gövdesine bir ağaç yapısı şeklinde ince yollarla iletir.
- *Axonlar*, elektriksel darbeler şeklindeki bilgiyi hücreden dışarı taşıyan daha uzun bir yoldur. Axonların bitimi, ince yollara ayrılabilir ve bu yollar, diğer hücreler için dendriteleri oluşturur.
- Şekil 29’da görüldüğü gibi axon-dendrite bağlantı elemanı *synapse* olarak söylenir.



Şekil 29. Biyolojik sinir hücre şekli

Synapse, gelen ve dendriteler tarafından alınan bilgiler genellikle elektriksel darbelerdir ancak, synapsedeki kimyasal ileticilerden etkilenir. Belirli bir sürede bir hücreye gelen girişlerin değeri, belirli bir eşik değerine ulaştığında hücre bir tepki üretir.

Hücrenin tepkisini artırıcı yöndeki girişler uyarıcı, azaltıcı yöndeki girişler ise önleyici girişler olarak söylenir ve bu etkiyi synapse belirler.

Yetişkin bir insan beyni yaklaşık olarak 10^{11} sinir hücresinden oluşmakta ve her bir sinir hücresinin ise ortalama 10.000 bağlantısı bulunmaktadır. İnsan beyninin değişik bölümleri değişik işlevleri yerine getirmek ile yükümlü olup bu bölgelerdeki sinir hücreleri genel anlamı ile aynı yapıyı göstermektedirler.

1.7.8. YSA'nın Yapısı

Sinir hücreleri bir grup halinde işlev gördüklerinde ağ (network) olarak adlandırılırlar ve böyle bir grupta binlerce nöron bulunur. Yapay nöronların birbirleriyle bağlantılar aracılığıyla bir araya gelmeleri yapay sinir ağını oluşturmaktadır. Yapay sinir ağıyla aslında biyolojik sinir ağının bir modeli oluşturulmak istenmektedir.

Nöronların aynı doğrultu üzerinde bir araya gelmeleriyle katmanlar oluşmaktadır. Katmanların değişik şekilde bir birleriyle bağlanmaları değişik ağ mimarilerini doğurur.


YSA'lar üç katmadan oluşur. Bu katmanlar sırasıyla;

- Girdi katmanı
- Ara Katman
- Çıktı Katmanıdır.

Girdi Katmanı: Bu katmandaki proses elemanları dış dünyadan bilgileri alarak ara katmanlara transfer ederler. Bazı ağlarda girdi katmanında herhangi bir bilgi işleme olmaz.

Ara Katman (Gizli Katman): Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderilirler. Bu bilgilerin işlenmesi ara katmanlarda gerçekleştirilir. Bir ağ içinde birden fazla ara katman olabilir.

Çıktı Katmanı: Bu katmandaki proses elemanları ara katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti için üretmesi gereken çıktıyı üretirler. Üretilen çıktı dış dünyaya gönderilir.



Şekil 30. Yapay sinir ağı modeli

1.7.9. YSA'nın Tasarımı

YSA uygulamasının başarısı, uygulanacak olan yaklaşımlar ve deneyimlerle yakından ilgilidir. Uygulamanın başarısında uygun metodolojiyi belirlemek büyük önem taşır. Yapay sinir ağının geliştirilmesi sürecinde ağın yapısına ve işleyişine ilişkin şu kararların verilmesi gerekir.

- Ağ mimarisinin seçilmesi ve yapı özelliklerinin belirlenmesi (katman sayısı, katmandaki nöron sayısı gibi)
- Nörondaki fonksiyonların karakteristik özelliklerinin belirlenmesi,
- Öğrenme algoritmasının seçilmesi ve parametrelerinin belirlenmesi,
- Eğitim ve test verisinin oluşturulması

Bu kararların doğru verilememesi durumunda, YSA'ları sistem karmaşıklığı artacaktır. Sistem karmaşıklığı yapısal ve toplam hesaplama karmaşıklığının bir fonksiyonudur. Toplam hesaplama karmaşıklığı ise, genellikle yapısal karmaşıklığın bir fonksiyonu olarak ortaya çıkar ve bu hesaplamanın en aza indirilmesi amaçlanır. Bu hesaplama karmaşıklığının ölçülmesinde de genellikle YSA sisteminin toplam tepki süresi veya sisteme ait bir işlemci elemanın tepki süresi değeri temel alınır. Bunun yanında kapladığı hafıza ve zaman karmaşıklığı bazı uygulamalarda hesaplanmaktadır. Bir YSA'nın uygun parametrelerle tasarlanması durumunda YSA sürekli olarak kararlı ve istikrarlı sonuçlar üretecektir. Ayrıca sistemin tepki süresinin yeterince kısa olabilmesi için

de ağ büyüklüğünün yeterince küçük olması gerekir. İhtiyaç duyulan toplam hesaplama da bu sayede sağlanmış olacaktır.

1.7.10. YSA Ağ Yapısının Seçimi

YSA'nın tasarımı sürecinde ağ yapısının seçilmesi, uygulama problemine bağlı olarak seçilmelidir. Hangi problem için hangi ağın daha uygun olduğunun bilinmesi önemlidir. Kullanım amacı ve o alanda başarılı olan ağ türleri Tablo 6'da verilmiştir.

Tablo 6. YSA türleri ve kullanım amaçları

Kullanım Amacı	Ağ Türü	Ağın Kullanımı
Tahmin	<ul style="list-style-type: none"> • ÇKA 	Ağın girdilerinden bir çıktı değerinin tahmin edilmesi
Sınıflandırma	<ul style="list-style-type: none"> • LVQ • ART • Counterpropagation • Olasılıklı Sinir Ağları 	Girdilerin hangi sınıfa ait olduklarının belirlenmesi
Veri İlişkilendirme	<ul style="list-style-type: none"> • Hopfield • Boltzman Machine • Bidirectional Associative Memory 	Girdilerin içindeki hatalı bilgilerin bulunması ve eksik bilgilerin tamamlanması

Uygun YSA yapısının seçimi, büyük ölçüde ağda kullanılması düşünülen öğrenme algoritmasına da bağlıdır. Ağda kullanılacak öğrenme algoritması seçildiğinde, bu algoritmanın gerektirdiği mimaride zorunlu olarak seçilmiş olacaktır. Örneğin geri yayılım algoritması ileri beslemeli ağ mimarisi gerektirir. Bir YSA'nın karmaşıklığının azaltılmasında en etkin araç, YSA ağ yapısını değiştirmektir. Gereğinden fazla sayıda işlemci eleman içeren ağ yapılarında, daha düşük genelleme kabiliyeti ile karşılaşılır.

1.7.11. Öğrenme Algoritmasının Seçimi

YSA yapısının seçiminden sonra uygulama başarısını belirleyen en önemli faktör öğrenme algoritmasıdır. Genellikle ağ yapısı öğrenme algoritmasının seçiminde belirleyicidir. Bu nedenle seçilen ağ yapısı üzerinde kullanılacak öğrenme

algoritmasının seçimi ağ yapısına bağlıdır. Yapay sinir ağının geliştirilmesinde kullanılacak çok sayıda öğrenme algoritması bulunmaktadır. Bunlar içinde bazı algoritmaların bazı tip uygulamalar için daha uygun olduğu bilinmektedir. Bu algoritmalar eğer uygun oldukları uygulama alanlarına göre sınıflandırılacak olursa, gruplar ve içinde yer alacak öğrenme algoritmaları aşağıdaki gibi özetlenebilir.

Tablo 7. Öğrenme algoritmaları ve uygulandıkları alanlar

Uygulama Tipi	Yapay Sinir Ağı
Öngörü Tanıma	<ul style="list-style-type: none"> • Geriyayılım • Delta Bar Delta • Geliştirilmiş Delta Bar Delta • Yönlendirilmiş Rastsal Tarama • Geriyayılım içinde kendini düzenleyen harita (Self Organizing Map) • Artansıralı sinir ağları (Higher Order Neural Networks)
Sınıflandırma	<ul style="list-style-type: none"> • Öğrenen vektör Ölçekleme (Learning Vektor Quantization) • Sayıcı Yayılımı (Counter-Propagation) • Olasılıklı Yapay Sinir Ağları
Veri İlişkilendirme (Data Association)	<ul style="list-style-type: none"> • Hopfield • Boltmann Makinesi • İki yönlü ilişkili bellek (Bidirectional Associative Memory) • Spantion – Geçici Örnek Tanıma (temporal Pattern Recognition)
Veri Kavramlaştırma (Data Conceptualization)	<ul style="list-style-type: none"> • Uyarlanabilir rezonans ağı (Adaptive Resonance Network) • Kendini Düzenleme (Self Organizing)

1.7.12. Ara Katman Sayısını Belirleme

YSA'nın tasarımı sürecinde tasarımcının yapması gereken diğer işlemde, ağdaki katman sayısına karar vermektir. Çoğu problem için 2 veya 3 katmanlı bir ağ tatmin edici sonuçlar üretebilmektedir. Nöronların aynı doğrultu üzerinde bir araya gelmeleriyle katmanlar oluşmaktadır. Katmanların değişik şekilde bir birleriyle bağlanmaları değişik ağ yapılarını oluşturur. Girdi ve çıktı katmanlarının sayısı, problemin yapısına göre değişir

[20]. Katman sayısını belirlemenin en iyi yolu, birkaç deneme yaparak en uygun yapının ve yapının ne olduğuna karar vermektir.

1.7.13. Nöron Sayısının Belirlenmesi

Ağın yapısal özelliklerinden birisi her bir katmandaki nöron sayısıdır. Katmandaki nöron sayısının tespitinde de genellikle deneme-yanılma yöntemi kullanılır. Bunun için izlenecek yol, başlangıçtaki nöron sayısını istenilen performansa ulaşmaya kadar arttırmak veya tersi şekilde istenen performansın altına inmeden azaltmaktır. Bir katmanda kullanılacak nöron sayısı olabildiğince az olmalıdır. Nöron sayısının az olması yapay sinir ağının “genelleme” yeteneğini artırırken, gereğinden fazla olması ağın verileri ezberlemesine neden olur. Ancak gereğinden az nöron kullanılmasının verilerdeki örüntünün ağ tarafından öğrenilememesi gibi bir sorun yaratabilir.

Nörondaki fonksiyonların da karakteristik özellikleri de YSA nun tasarımında önemli kararlardan biridir. Nöronun geçiş fonksiyonunun seçimi büyük ölçüde yapay sinir ağının verilerine ve ağın neyi öğrenmesinin istendiğine bağlıdır. Geçiş fonksiyonları içinde en çok kullanılanı sigmoid ve hiperbolik tanjant fonksiyonlarıdır. Daha önce belirtildiği gibi sigmoid fonksiyonun çıktısı 0 ve 1 arasında olurken, hiperbolik tanjant fonksiyonunun çıktısı -1 ve 1 aralığında oluşmaktadır. Eğer ağın bir modelin ortalama davranışını öğrenmesi isteniyorsa *sigmoid fonksiyon*, eğer ortalamadan sapmanın öğrenilmesi isteniyorsa *hiperbolik tanjant fonksiyon* kullanılması önerilmektedir.

1.7.14. Normalizasyon

YSA'ların en belirgin özelliklerinden olan doğrusal olmama özelliğini anlamlı kılan yaklaşım, verilerin bir normalizasyona tabii tutulmasıdır. Verilen normalizasyonu için seçilen yöntem YSA performansını doğrudan etkileyecektir. Çünkü normalizasyon, giriş verilerinin transfer edilirken fonksiyonun aktif olan bölgesinden aktarılmasını sağlar. Veri normalizasyonu, işlemci elemanlarını verileri kümülatif toplamların oluşturacağı olumsuzlukların engellenmesini sağlar. Veri normalizasyonu, işlemci elemanlarını verileri kümülatif toplamlarla koruma eğilimleri nedeniyle zorunludur ve aşırı değerlendirilmiş kümülatif toplamların oluşturacağı olumsuzlukların engellenmesini sağlar. Genellikle

verilerin $[0,1]$ veya $[-1,+1]$ aralıklarından birine ölçeklendirilmesi önerilmektedir. Ölçekleme verilerin geçerli eksen sisteminde sıkıştırılması anlamı taşıdığından veri kalitesi aşırı salınımlar içeren problemlerin YSA modellerini olumsuz yönde etkileyebilir. Bu olumsuzluk, kullanılacak öğrenme fonksiyonunu da başarısız kılabilir.

1.7.15. Basit Algılayıcı Modeli (Perseptron)

Tek katmanlı YSA'lar sadece girdi ve çıktı katmanından oluşurlar. Her ağın bir ya da daha fazla girdisi ve bir çıktısı vardır. En basit şekli ile tek katmanlı bir ağa örnek olarak aşağıdaki şekil verilir.

Her bağlantının bir ağırlığı (W_1) vardır. Yukarıdaki şekilde ağın iki girdisi ve bir çıktısı olduğu görülmektedir. Bu ağlarda, proses elemanlarının değerlerinin ve dolayısıyla ağın çıktısının sıfır olmasını önleyen bir de eşik değeri vardır ve bu değer 1'dir. Tek katmanlı algılayıcılarda çıktı fonksiyonu doğrusal fonksiyondur. Ağa gösterilen örnekler iki sınıf arasında paylaştırılarak iki sınıfı birbirinden ayıran doğru bulunmaya çalışılır. Bunun için eşik değeri fonksiyonu kullanılmaya çalışılır. Burada ağın çıktısı +1 veya -1 değerini almaktadır. (+1) ve (-1) sınıfları temsil etmektedir. Eğer ağın çıktısı (+1) ise birinci sınıfta, (-1) ise ikinci sınıfta kabul edilmektedir.

- Eğer Çıktı >0 ise (+1) sonucunu,
- Eğer Çıktı <0 ise (-1) sonucunu üretmiş olacaktır.

Burada öğrenme ile kast edilen, bu iki sınıfı en iyi şekilde ayırabilmektir. Bunun için de ağırlık değerlerinin değiştirilmesi gerekir. t zaman biriminde ağırlık değeri DW kadar değiştirilir ise; $W_i(t+1) = W_i(t) + DW_i(t)$ olacaktır.

Öğrenme sırasında bu değişim her iterasyonda gerçekleştirilerek iki sınıfı birbirinden ayıran sınıf ayırıcının en doğru sonucu bulması amaçlanır. Aynı şekilde eşik değeri de her iterasyonda Df kadar değiştirilir ve yeni eşik değeri aşağıdaki formül ile hesaplanır.

$$f_i(t+1) = f_i(t) + Df_i(t) \quad (13)$$

Tek katmanlı algılayıcılarda önemli iki modelden bahsedilebilir. Bunlar ;

- Basit Algılayıcı (Perseptron)
- Adeline / Madalinedir.

1.7.16. Çok Katmanlı Sinir Ağları

Girdi ile çıktı arasındaki ilişkinin doğrusal olmadığı bir problemi, ADELİNE ile çözmek mümkün olamamıştır. Özellikle, Minsky, basit algılayıcı modelin bu probleme çözüm getirmediğini göstermiş ve YSA'ların doğrusal olmayan problemlerin çözümünde kullanılamayacağını iddia etmiştir. Çünkü günlük hayatta karşılaşılan problemlerin hemen hepsi doğrusal olmayan nitelik taşımaktadır. Bu durum, YSA ile ilgili yapılan bilimsel araştırmaların pek çoğunun durmasına neden olmuştur. Birkaç araştırmacının çalışmalarına devam ederek YSA'nın doğrusal olmayan problemlerin de çözümünde kullanıldığını göstermeleri ile YSA ile ilgili çalışmalar tekrar hız kazanmıştır.

Doğrusal olmayan bir ilişki gösteren XOR problemini çözmek amacıyla yapılan çalışmalar sonucunda Çok Katmanlı Algılayıcı modeli geliştirilmiştir. Rumelhart ve arkadaşları tarafından geliştirilen bu modele hata yayma modeli veya geriye yayılım modeli (backpropagation network) de denilmektedir. ÇKA modeli yapay sinir ağlarına olan ilgiyi çok hızlı bir şekilde arttırmış ve YSA tarihinde yeni bir dönem başlatmıştır. Bu ağ modeli özellikle mühendislik uygulamalarında en çok kullanılan sinir ağı modeli olmuştur. Bir çok öğretim algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir.

Bir ÇKA modeli, bir giriş, bir veya daha fazla ara ve bir de çıkış katmanından oluşur. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Bunun için ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı tamamen uygulanan problemlerin giriş sayısına bağlıdır. Ara katman sayısı ve ara katmanlardaki işlem elemanı sayısı ise, deneme-yanılma yolu ile bulunur. Çıkış katmanındaki eleman sayısı ise yine uygulanan probleme dayanılarak belirlenir. Delta Öğrenme Kuralını kullanan bu ağ modeli, özellikle sınıflandırma, tanıma ve genelleme yapmayı gerektiren problemler için çok önemli bir çözüm aracıdır.

ÇKA modelinin temel amacı, ağı beklenen çıktısı ile ürettiği çıktı arasındaki hatayı en aza indirmektir. Bu ağlara eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi gereken (beklen) çıktılar gösterilir (danışmanlı öğrenme). Ağı görevi her girdi için o girdiye karşılık gelen çıktıyı üretmektir. Örnekler giriş katmanına uygulanır, ara katmanlarda işlenir ve çıkış katmanından da çıkışlar elde edilir. Kullanılan eğitime

algoritmasına göre, ađın ıkıřı ile arzu edilen ıkıř arasındaki hata tekrar geriye dođru yayılarak hata minimuma düşünceye kadar ađın ađırlıkları deđiřtirilir.

1.7.17. YSA Öđrenme Algoritmaları

Yapay sinir ađının geliřtirilmesinde kullanılacak ok sayıda öđrenme algoritması bulunmaktadır. Bunlar içinde bazı algoritmaların bazı tip uygulamalar için daha uygun olduđu bilinmektedir.

1.7.18. Temel Öđrenme Kuralları

Literatürde kullanılan ok sayıda öđrenme algoritması bulunmaktadır. Bu algoritmaların ođunluđu matematik tabanlı olup ađırlıkların güncelleřtirilmesi için kullanılırlar. Yapay sinir ađının mimarisine, karřılařılan sorunun niteliđine göre farklılık gösteren bu öđrenme algoritmalarının yüzde fazla eřidi bulunmaktadır. Bu algoritmaların bir ođu ařađıda sırlanan kurallardan esinlenerek geliřtirilmiřtir.

- Hebb Kuralı
- Delta Kuralı
- Kohonen Kuralı
- Hopfield Kuralı

1.7.19. Hebb Kuralı

1949 yılında Kanadalı psikolog Donald Hebb tarafından biyolojik temele dayalı olarak geliřtirilmiř olan Hebb algoritması en eski ve en ünlü öđrenme algoritmasıdır. Bu öđrenme algoritması basit bir mantıđa dayanmaktadır: Eđer nöron (A) bařka bir nöron' dan (B) girdi alıyorsa ve her ikisi de aktifse, (A) ve (B) arasındaki ađırlık artar.

1.7.20. Delta Kuralı

Delta kuralı ilk olarak Widrow ve Hoff tarafından geliştirilmiş daha çok mühendislik kökenli bir algoritmadır. Bu kural, nöronun gerçek çıkışı ile istenilen çıkış değerleri arasındaki farkı azaltan, giriş bağlantılarını güçlendiren ve sürekli olarak değiştiren bir düşünceye dayanmaktadır. Delta kuralı, ortalama karesel hatayı, bağlantı ağırlık değerlerinin değiştirilmesi ile düşürme prensibine dayanır. Bu nedenle de bu algoritma en küçük kareler kuralı olarak da bilinmektedir (Least-Mean-Square Rule LMS). Hata aynı anda bir katmandan bir önceki katmanlara geri yayılarak azaltılır. Ağın hatalarının düşürülmesi işlemi, çıkış katmanından giriş katmanına ulaşıncaya kadar devam eder.

1.7.21. Kohonen Kuralı

Bu kural, biyolojik sistemlerdeki öğrenmeden esinlenerek Kohonen tarafından geliştirilmiştir. Bu kuralda nöronlar öğrenmek için yarışır. Kazanan nöronun ağırlıkları güncellenir. Bu kuralı “kazanan tamamını alır” olarak da bilinir. En büyük çıkışa sahip işlemci nöron kazanır. Bu nöron, komşularını uyarma ve yasaklama kapasitesine sahiptir. Kohonen kuralı, hedef çıkışa gereksinim duymaz. Bu nedenle danışmansız bir öğrenme metodudur.

1.7.22. Hopfield Kuralı

Bu kural, zayıflatma ve kuvvetlendirme büyüklüğü dışında Hebb Kuralına benzerdir. Eğer istenilen çıkış ve girişin her ikisi aktif veya her ikisi de aktif değilse öğrenme oranı tarafından bağlantı ağırlığı artırılır. Diğer durumlarda ise azaltılır. Birçok öğrenme algoritmasında öğrenme katsayısı oranı veya sabiti vardır. Genellikle bu terim 0 ile 1 arasında değerler almaktadır.

1.7.23. Öğrenme Algoritmaları

1.7.23.1. Geriyayılım Algoritması

Yapay sinir ağları belki de en çok tahmin amacıyla kullanılmaktadır. Tahmin için kullanılan yapay sinir ağları içinde de en yaygın olarak kullanılanı geriyayılım algoritmasıdır. Geriyayılım algoritması ileri beslemeli ve çok katmanlı bir ağ mimarisini gerektirmektedir.

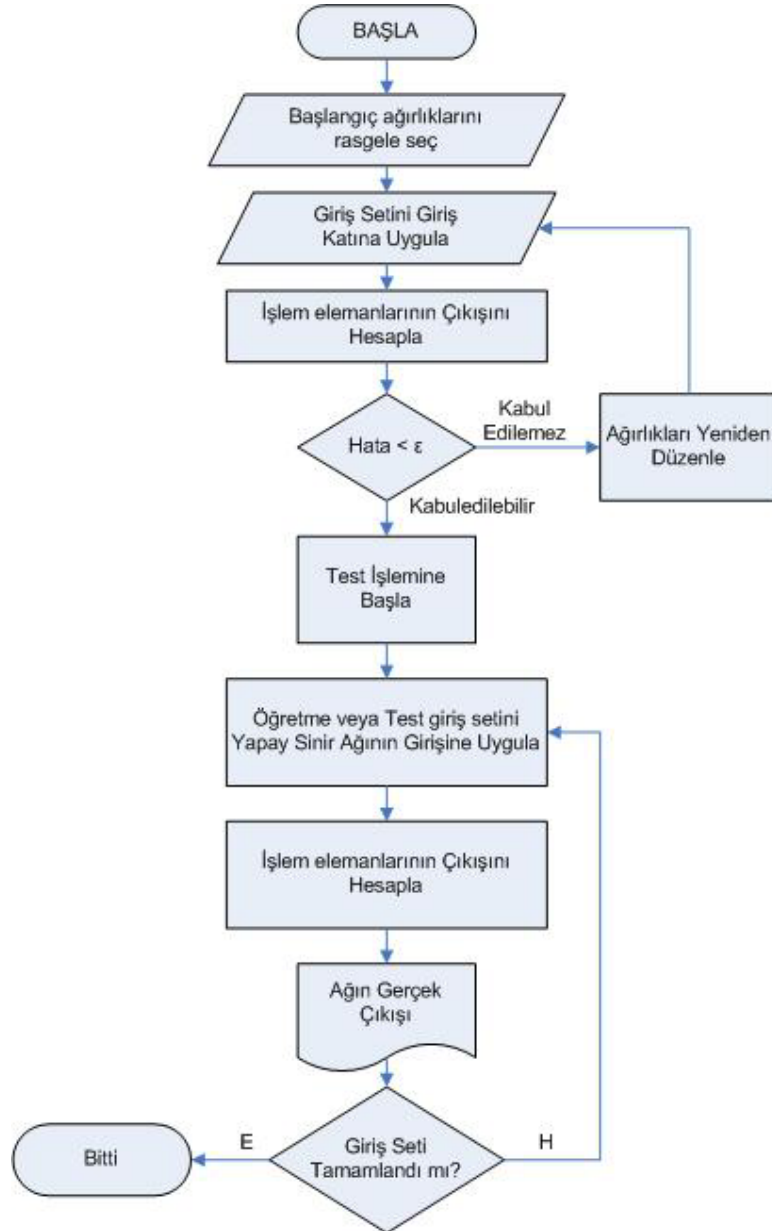
Geriyayılım Algoritması, YSA'lar açısından en önemli tarihsel gelişmelerden biridir. Geriyayılım algoritması veya bir başka adıyla Genelleştirilmiş Delta Algoritması uygulamada en çok kullanılan öğretim algoritmasıdır. Hata, ağdaki ağırlıkların bir fonksiyonu olarak görülür ve hataların kareleri ortalaması delta kuralında olduğu gibi dereceli azaltma (gradient descent) yöntemi kullanılarak, minimize edilmeye çalışılır. Bu algoritma, hataları çıkıştan girişe geriye doğru azaltmaya çalışmasından dolayı geriyayılım ismini almıştır. Geriyayılım algoritması, ÇKA'ları eğitmede en çok kullanılan temel bir öğrenme algoritmasıdır. Eğitim işlemi ve eğitimden sonraki test işlemi bu akışa göre gerçekleştirilir.

Geri yayılım algoritması, gözetmenli öğrenme yöntemini kullanılır. Örnekler ağa öğretilir ve ağa hedef değeri verilir. Öğrenme, her örnek için ağın çıktı değeri ile hedef değerinin ile karşılaştırılır. Hata değeri, ağa tekrar geri besleme şeklinde verilir. Örnek setindeki hata kareleri toplamını azaltmak için nöronlar arasındaki bağlantı ağırlıkları değiştirilir [21].

Tipik çok katlı geri yayılım ağı, daima; bir giriş tabakası, bir çıkış tabakası ve en az bir gizli tabakaya sahiptir. Gizli tabakaların sayısında teorik olarak bir sınırlama yoktur. Fakat genel olarak bir veya iki tane bulunur. Desen sınıflandırma problemlerini çözmek için maksimum dört tabakaya (üç gizli ve bir çıkış tabakası) gereksinim duyulduğuna işaret eden bazı çalışmalar yapılmıştır. Geri yayılım algoritması, gradyan azalan ve MLP'leri eğitmede en çok kullanılan temel bir algoritmadır. Bu algoritmanın akış şeması Şekil 31'de verilmiştir.

Burada, gizli katman sayısını tespit etmek zor bir işlemdir. Gizli katmanlar, lineer olmayan ya da değişkenler arasında etkileşim var ise kullanılır. Bu etkileşim ne kadar karmaşıkça, o kadar çok gizli katmana ihtiyaç duyulur. Eğer az sayıda gizli katman kullanılırsa ağ öğrenmeyi başarmaz. Gereğinden fazla sayıda gizli katman bulunması

halinde ise, ağı ezberler. Bu da ağın, yeni örnekler için genelleme yeteneğini azaltır. Amaç, ağın genelleme yeteneğini optimum yapabilecek en az sayıda katmanı kullanmaktır. Ağı doğru zamanda durdurmak, ağın ezberlemesini önler. Gizli katman sayısını belirlemenin hızlı bir yolu yoktur. Bunu belirlemek için benzer veri seti kullanılmış tecrübelerden faydalanılabilir [22].



Şekil 31. Geri yayılım algoritmasının akış şeması

Geri yayılım algoritmasının bir dezavantajı, yakınsama hızının yavaş olması ve yerel en iyi çözümlerde durabilmedir. Bunu gidermek için literatürde değişik çözüm yolları geliştirilmiştir. Bunlardan biriside YSA'nın Tabu Algoritması ile eğitilmesidir. Çözüm uzayında bir hareket elde etmek için, ağırlık kümesindeki tüm ağırlıkları değiştirmek yerine, ağırlıklardan sadece birini değiştirerek çözüm uzayının daha detaylı aranması amaçlanmıştır [23]. Arıca Ç. Alabaş ve B. Deniziz'in Tabu Arama Algoritması ile Yapay Sinir Ağlarının Eğitimi konulu bu makalesinde, değiştirilecek olan ağırlığın alacağı yeni değer rassal olarak seçilse de, tabu listesinde kayıtlı olan önceki örneklerden belli bir dereceye kadar farklı olması kısıtı konmuştur. Böylelikle kontrollü bir rassallık kullanılmıştır. Ağırlıkları taşıyan ok numaraları da tabu listelerinin oluşturulmasında kullanılmıştır. Öğrenme algoritması olarak geriyayılım algoritması seçildiğinde iki parametre önem kazanmaktadır. Bunlar öğrenme katsayısı η , (learning rate) ve momentum terimidir α 'dır. Bu algoritma ile i ve j kat işlem elemanları arasındaki ağırlıklardaki $\Delta w_{ij}(t)$ değişikliği hesaplanır. Bu ifade;

$$\Delta w_{ij}(\tau) = \eta \cdot \delta_j \cdot x_i + \alpha \Delta w_{ij}(\tau-1) \quad (14)$$

olarak verilir.

η : Öğrenme katsayısıdır. Öğrenme katsayısı, ağırlıkların bir sonraki düzeltmede hangi oranda değiştirileceğini göstermektedir. Küçük öğrenme katsayıları, ağırlıkların sonuca ulaşmasını yavaşlatır. Büyük öğrenme katsayıları, ağırlıkların sonuca daha kısa sürede ulaşmasını sağlar. Bununla birlikte çok yüksek oranlar ağırlıkların hesaplamalarında büyük salınımlara neden olur ve ağırlıkların dip noktayı bulmasını engelleyebilir. Öğrenme katsayısı için tipik değerler 0,01 ile 0,9 arasında değişir. Karmaşık ve zor çalışmalar için küçük öğrenme katsayıları seçilmesi önerilir.

α : Momentum katsayısıdır. momentum terimi, ağırlıklardaki salınımları engellemeye ve ağırlıkların hata yüzeyindeki bölgesel minimum noktalardan kaçarak, daha dip noktalara ulaşmasına yardımcı olur. Optimal öğrenme oranı ve momentum teriminin belirlenmesi büyük ölçüde deneysel ve sezgisel bir özellik taşır. Ayrıca bu parametreler büyük ölçüde ilgilenilen sorun alanına bağlı olarak değişiklik gösterir.

δ_j : Ara veya çıkış katındaki herhangi bir j nöronuna ait bir faktördür. Çıkış katı için bu faktör aşağıdaki şekilde verilir.

2. YAPILAN ÇALIŞMALAR

Çalışmada, görüntü üzerinde çalışılabilmesi ve sonuçların eldeki örnekler için de hesaplanabilmesi amacıyla genel bilgiler kısmında bahsedilen bazı yöntemler uyulama olarak geliştirilmiş ve sonuçları incelenmiştir.

Çalışmadaki amaç, elimizdeki örneklere ve amacımıza uygun olan farklı bir yöntem geliştirmek olması nedeniyle, geliştirilen program, bahsi geçen yöntemlerin her birinin sonucu üzerinde diğer bir yöntemin sonuç üretebileceği ve üretilen sonuçların kaydedilebileceği şekilde tasarlanmıştır.

Hedeflenen görüntü üzerindeki her bir hücrenin ayrı olarak ele tespit edilmesidir. Daha sonra bulunan hücrelerin tipi ve yapısı araştırılacak olan tanıma sürecine gidilecektir.

İncelenen görüntüler, internetteki hematoloji atlası sitesinden alınmıştır. Görüntüler “jpg” veya “bmp” formatında alındığından üzerelerinde işlenecek görüntü üzerinde sıkıştırma işleminden ve çekim sırasında kullanılan kameradan kaynaklanan bazı olumsuz etkiler de olmaktadır.

2.1. Gri seviye dönüşümü

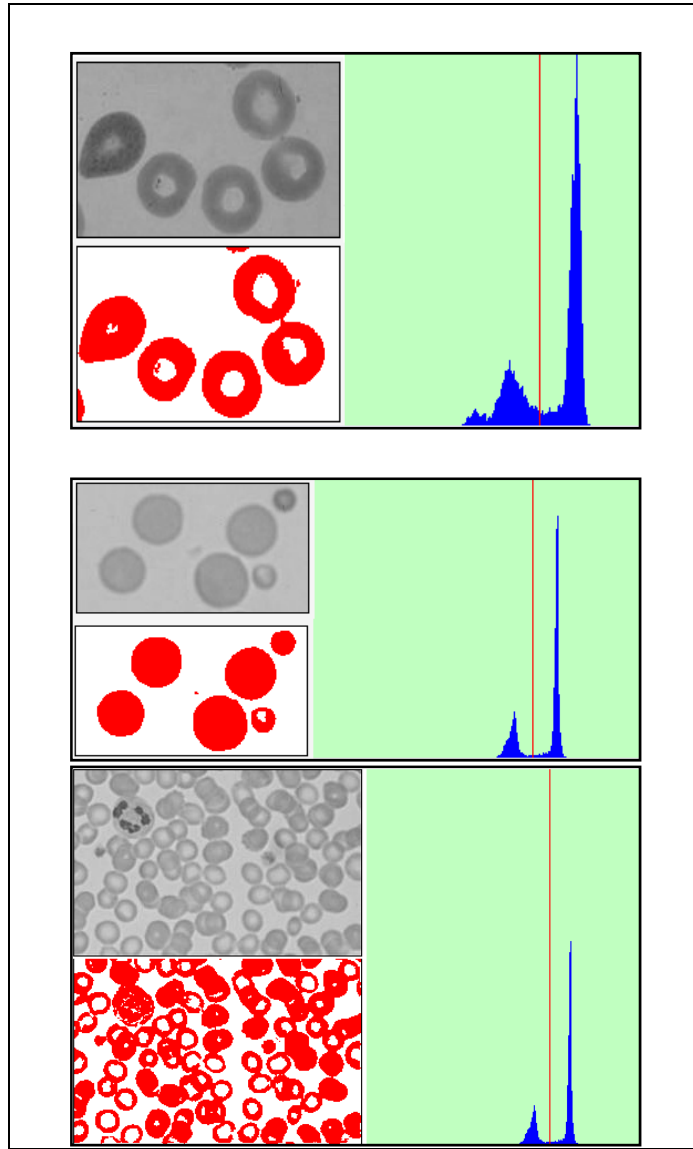
Gri seviye dönüşümünün nedenlerini açıklarken asıl amaç olan bölütlemeye veri hazırlamak olduğu unutulmamalıdır. Bu bakış açısıyla bakıldığında gri seviye dönüşümü yapılmasının nedenleri:

- Periferik yayma sonucu, görüntünün farklı renk ağırlıklarında olmasıdır. (Şekil 1’de görüldüğü gibi hücre, kırmızı ağırlıklı olsa kırmızı renk güçlendirilerek, sonuca gidilmesi daha kolay olabilirdi.)
- Gri seviye iz düşümüyle görüntünün parlaklık bilgisiyle derinlik bilgisinin çıkarılabilmesi sağlanacaktır. (Bu bilgi ilerde Watershed dönüşümü için kullanılacaktır.)
- İşlenecek bilgi miktarının azalması dolayısıyla işlem hızının artmasını sağlayacak buna karşılık bazı detay bilgilerin yok olmasına neden olacaktır.
- Hesaplanan tüm noktalardan oluşan yeni örüntü, işlenerek hücrelerin ayıklanacağı zemini oluşturmaktadır.

Periferik Yayma görüntülerindeki hücrelerin kenar bilgileri kuvvetlendirilerek hücre sınırları belirgin hale getirilir. Eşikleme, iyileştirme ve eleme işlemleri sonucunda hücreler tespit edilerek tanıma aşamasına geçilecektir.

2.2. Hücre Sınırlarının Belirlenmesi

Görüntünün eşik değeri Otsu yöntemiyle araştırıldığında şu sonuçlar ortaya çıkmaktadır. Ayırık ve bitişik farklı boyutlardaki eritrosit görüntüleri üzerinde gerçekleştirilen eşikleme işlemleri histogramlarıyla aşağıda gösterilmektedir.



Şekil 32. Eşikleme sonuçları


Eritrosit hücrelerinin kenarlarının belirlenmesi görünüş üzerindeki hücre sayısının tespit edilmesi ve tanımlanması için gereklidir. Hücre kenarlarının tespiti için genel bilgiler kısmında bahsedilen kenar güçlendirici filtreler kullanılmıştır.

2.3. Hough Dönüşümünün Probleme Uygulanması

Eritrosit hücrelerinin şekillerinin çember ve elipse benzerliği görülmektedir. Bu nedenle, hücreleri çevreleyen çemberlerin tespitinde hough dönüşümü kullanımı düşünülmüştür. Hücreleri çevreleyen çemberlerin tespitiyle:

1. Hücre sayımı yapılabilmesi sağlanacaktır.
2. Bitişik hücrelerin eksik parçaları tamamlanacaktır.
3. Hücrenin kenarları ve çevreleyen çember arasındaki uzaklıkları, arada kalan boş alanlar gibi hücre tipi ve anemi türünün belirlenmesine yardımcı olan bilgiler elde edilecektir.

Eritrositlerin çevrelerinin bulunabilmesi için öncelikle renkli görüntü gri tonlara dönüştürülmekte, kenarları Sobel Maskesi uygulanarak güçlendirilmekte ve daha sonra eşikleme yapılarak ikili görüntü haline getirilmektedir. Elde edilen ikili görüntünün üzerinde CHT uygulanarak çemberler tespit edilmektedir. Çemberlerin tespit adımları Şekil 33'te gösterilmektedir.




Şekil 33. CHT uygulama sonucu

Şekil tespitinde karşılaşılabilecek olan temel sorunlar şunlardır:

1. Parametre uzayında gerçeklik değerleri eşik değerinin iyi seçilmemesi nedeniyle görüntü üzerinde kenar olmayan bilgilerin de işleme katılarak yalancı doğrular oluşturması veya görüntüde var olan çemberin eşikleme sonucunda tespit edilememesi.

2. Çember belirlenirken ($\Delta\Theta$) değerinin, büyük seçilmesi durumunda var olan çemberi temsil eden parametre bilgilerinin gerçeklik değerinin artırılmaması, küçük seçilmesi durumunda ise çakışan çevre noktaları nedeniyle gerçeklik değerlerinde tutarsızlık olması sonucu küçük yarıçaplı çemberlerin fazlaca bulunması. ($\Delta\Theta$) değerinin optimum seçilebilmesi.
3. Görüntüdeki bir çember görünümü nesne için birden fazla eğri tespit edilmesi.
4. Gürültünün ortadan kaldırılmaması durumunda gürültü miktarının artmasından kaynaklanan sahte çemberlerin tespitinin önlenmesi gerekmektedir.

Geliştirilen programda, hough dönüşümü uygulayabilmek için ikili halde kenar bilisi içeren bir bilgi oluşturulmalıdır. Görüntü, Hough dönüşümüne hazır hale getirmek için Öncelikle gri seviyeye dönüştürülür. Sonrasında eşik değeri belirlenerek ikili hale getirilir. İkili hale getirilen görüntüdeki artalandan ayrılmış olan nesnelerin sınır bilgisine ulaşmak için dairesel bölgelerin içi boşaltma yöntemiyle boşaltılır. Yazılım tarafından çember araştırma için hazır hale getirilen görüntü Şekil 34’te görülmektedir.

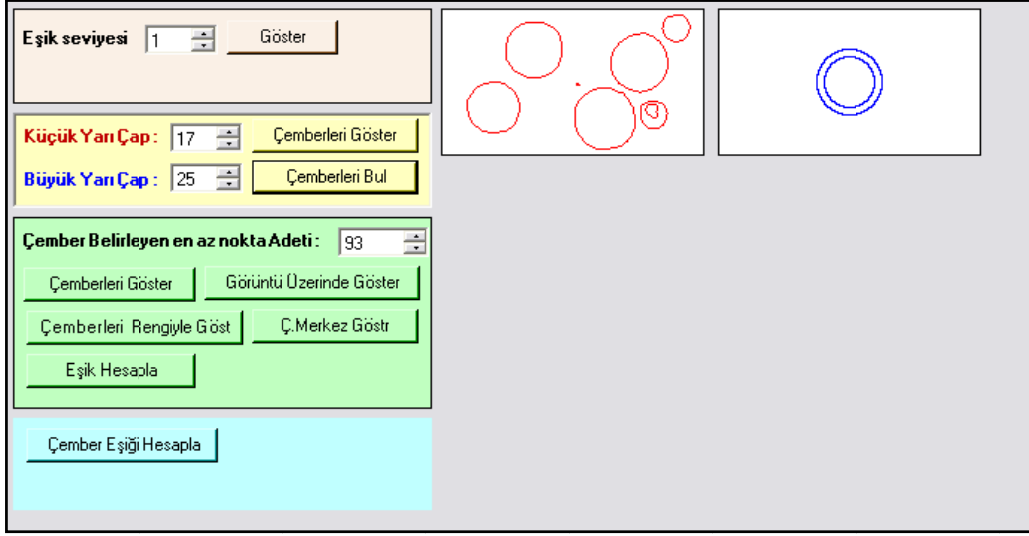


Şekil 34. Hough dönüşümü için boşaltma ile hazırlanan veri

Çember araştırmak için elde edilen verinin sınır çizgilerinin birleşmesi veya şekil üzerinde inceltmeler yapılması incelenecek piksel sayısını azalttığı için zaman kazandıracak ve gereksiz çemberlerin bulunmasını önleyecektir. Çemberlerin araştırılması için geliştirilen program arayüzü Şekil 35’te görülmektedir. Öncelikle görüntü üzerinde araştırılacak olan en küçük ve en küçük piksel yarıçapları belirtilerek ön izlemeyle ekranda gösterilir (En sağda iç içe görünen çemberler).


Çember araştırma işlemi genel bilgiler kısmında hough dönüşümü başlığı altında detaylıca anlatılmıştır.

Yazılım araştırılan çemberlerden, şekil üzerindeki piksellerle en fazla eşleşen nokta sayısını ekranda gösterir. Kullanıcı bu nokta sayısının altında bir değerle araştırma yaptığında eşleşen çemberleri ekranda görebilecektir.




Şekil 35. Hough dönüşümü için geliştirilen yazılım arayüzü

Örnekte belirtilen aralıktaki ([17,25] piksel yarı çap aralığı) çemberler arasından en çok 93 piksellik eşleşme görülmüştür. Şekil 36'da ilk tespit edilen çember görülmektedir.



Şekil 36. İlk bulunan çember


Eşleşen nokta sayısı değeri 70 piksel olarak seçildiğinde tespit edilen çemberler Şekil 37'de görülmektedir.



Şekil 37. Eşleşen piksel değeri 70 seçildiğinde bulunan çemberler

Eşleşen piksel değeri daha küçük bir değer seçildikçe tespit edilen çemberlerin piksel komşuluklarındaki çemberler dışında farklı bir çember tespit edilemeyecektir. Görüntü üzerinde görülen sol alt kısımdaki çemberin tespit edilmeme nedeni ise araştırılan yarıçap aralığında olmamasıdır.

Tespit edilen çemberlerin üst üste tekrar sayılmaması için tespit edilen çemberlerin merkezlerinin oluşturduğu görüntü incelenerek, merkez noktalar gruplandırılarak asıl çemberlere ulaşılmaktadır. Şekil 38’de çember merkezlerinin oluşturduğu dört nokta grubu görülebilmektedir.




Şekil 38. Tespit edilen çember merkezleri

Çembersel sınırı belirlenen hücreler sayıma katılarak, tanıma işlemi için geliştirilen yapay sinir ağına iletilecektir.

2.3.1. Etiketleme

İkili görüntü üzerinde bağımsız nokta kümelerinin farklı hücreler olması olasılığı yüksektir. Bu amaçla farklı nokta kümelerinin ayrı ayrı incelenebilmesi için etiketleme işlemi yapılmaktadır.

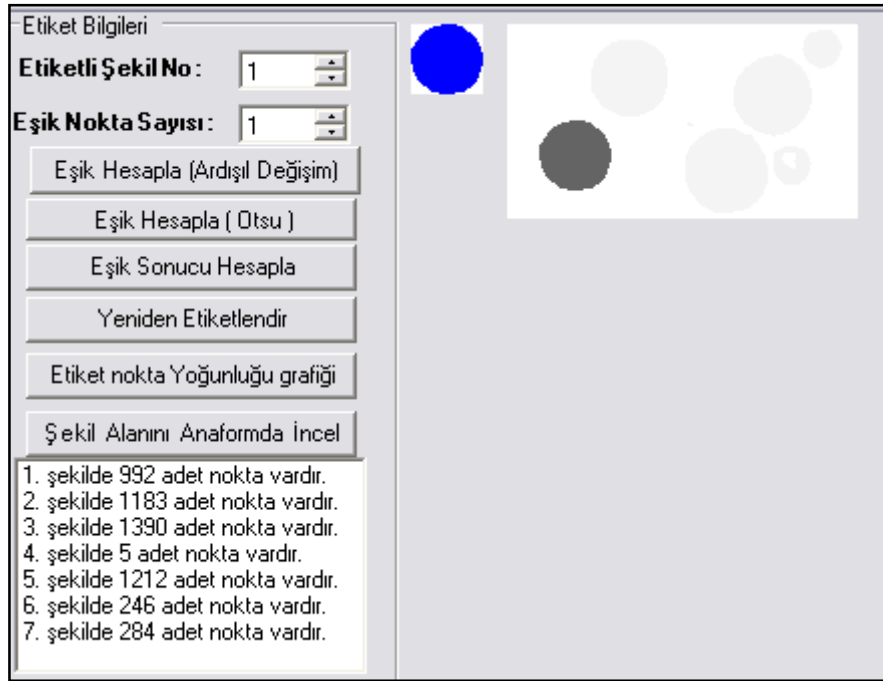
Az önceki görüntü eşikleme sonrası ayrıştırılmak istendiğinde Şekil 39’da görülen farklı renkli daireler ortaya çıkmaktadır. Görüntüden yedi farklı grup elde edilmiştir.



Şekil 39. İkili görüntünün etiketlenmesi

Görünürde altı adet hücre benzeri görüntü varken yedi adet sınıf oluşturulması görüntünün ortasında bulunan küçük şekilden kaynaklanmaktadır. Bu şekil yoğunluk analizi hemen elenmektedir.

Etiketlendirme sırasında tespit edilen küçük cisimlerin elenmesi için ek bir yazılım geliştirilmiştir. Geliştirilen yazılımın arayüzü Şekil 40'da görüldüğü gibidir. Yazılım etiketlendirdiği cisimlerin piksel yoğunluğu (alan) bilgileriyle bir histogram oluşturmakta ve ortama göre düşük yoğunlukta olan cisimlerin dikkate alınmayacağı bir yoğunluk eşiği tespit etmektedir.



Şekil 40. Etiket yoğunluk analiz arayüzü

Yazılım, her bir etiketli şekli bağımsız olarak gösterebilmekte yoğunluğunu göstermektedir.

2.3.1. Yapay Sinir Ağı

Geliştirilen yapay sinir ağı, eğitim seti parametrelerinin kaydedilmesi ve dosyadan yüklenmesini sağlamakta. Bu sayede eğitime kaldığı yerden devam edebilmektedir. Geliştirilen ağın giriş eleman sayısı, gizlik katman sayısı ve her bir gizli katmanın eleman

sayıları ve çıkış katmanı eleman sayısı dinamik olarak seçilebilmektedir. Ağ yapısı dosyalanabilmekte ve dosyadan tekrar geri yüklenerek değiştirilebilmektedir.

Geliştirilen ağın dinamikliğini sağlayan yapısal kodlar aşağıda gösterilmektedir. Geliştirilen yapıda Yapay sinir ağı katmanlardan, katmanlar elemanlardan (nöron) oluşmaktadır. Her bir yapay sinir hücresini sonraki katmandaki her hücreye bağlayan ağırlık değerleri de bu yapılarda saklanmaktadır.

Temel ağ bileşeni olan sinir hücresinin yapısını belirleyen kod parçası aşağıdadır.

```
public struct hucre{
    public double[] agirliklar;
    public double[] agirlik_deg;
    public double cikis_degeri;
    public double hata_degeri;
    public double cikis_hata_deg;
}
```

Sinir hücrelerin bulunduğu katmanın yapısını belirleyen kod parçası aşağıdaki gibidir.

```
public struct katman{
    public int eleman_sayisi;
    public hucre[] eleman;
    public hucre esik_elemani;
    public double[] hata_agirlik_carp_top;
}
```

Bütün bu yapıları içeren ve tüm ağı kapsayan yapısal kod parçası aşağıdaki gibidir. Ağın katman sayısı ve her katmandaki eleman sayıları bu şekilde kullanılmaktadır.

```
public struct ysa_yapisi
{
    public int katman_sayisi;
    public int[] eleman_sayilari;
    public katman[] katmanlar;
}
```

Ağı eğitmek için kullanılan örneklerin ve bu örneklere karşılık ağdan beklenen sonuçların ağa sunulması için geliştirilen yapıyı belirleyen kodlar aşağıdadır.

```
public struct ornek
{
    public double[] giris_degerleri;
    public double[] beklenen_degerler;
}
public struct egitim_seti_ozellikleri
{
    public decimal ornek_sayisi;
    public decimal ornek_en;
    public decimal ornek_boy;
    public decimal ornek_cikis_sayisi;
    public string set_adi;
}
```

Yapay sinir ağı için gerçekleştirilen yazılımın ekran görüntüsü iki farklı arayüzden oluşmaktadır. Bir arayüz eğitim seti için örnekleri ve beklenen değerleri kullanıcının oluşturabilmesi için geliştirilmiştir. Şekil 40’da eğitim seti için geliştirilen arayüz ve aldığı parametreler görülmektedir.

Eğitim setine örnekler eklenmeden önce birim örnek boyutları belirlenmelidir. Böylece eğitilecek yapay sinir ağının giriş eleman sayısı da hesaplanarak ekrana yansıtılmakta ve eğitimde kullanılacak ağ yapısına da seçilen örneklere uygun kısıtlamalar getirilmektedir.

Ağın çıkış elemanı sayısının belirtilme zorunluluğu beklenen değerlerin değişim aralığının kısıtlanmasıdır. Sonuçta iki çıkış elemanı en fazla dört farklı çıkış değeri sunabilecektir. Kullanıcının farklı değerler girmesi ağın sürekli hataya düşmesine ve sonsuz bir eğitim sürecine girmesine neden olacaktır. Bu nedenle program belirtilen ağ çıkış eleman sayısını dikkate alarak kullanıcının girebileceği beklenen değer aralığını kısıtlamaktadır. Bu kısıtlama tam sayısal bir kısıtlama olup. Ondalık olarak beklenen değer girilemeyeceği varsayılmaktadır.

Şekil 41. Eğitim seti oluşturma arayüzü

Şekil 42. YSA eğitim arayüzü

Şekil 42’de görülmektedir. Ağın yapısına ve eğitim şekline bu arayüz ile karar verilmektedir. Eğitim için gereken öğrenme ve momentum katsayıları da yine bu arayüz aracılığıyla belirtilmektedir.

Eđitim, belirtilen kabul edilebilir hata miktarının altına gelene kadar sürdürülebildiđi gibi, ađ belirtilen iterasyon (tekrar) sayısı kadar da örneklerle eđitilebilmektedir. Eđitim sırasında oluřan deđerlerin görülebilmesi için sadece bir kutucuk iřaretlenmesi yeterlidir.

Eđitim, belirtilen kabul edilebilir hata miktarının altına gelene kadar sürdürülebildiđi gibi, ađ belirtilen iterasyon (tekrar) sayısı kadar da örneklerle eđitilebilmektedir. Eđitim sırasında oluřan deđerlerin görülebilmesi için sadece bir kutucuk iřaretlenmesi yeterlidir.

Yapılan eđitimlerde parlaklık deđerinin farklı olmasından dolayı örneklerin eđitimi mümkün olmamıřtır. Parlaklıkların farklılıđından dolayı karřılařılan problem, sonrasında iyi örneklerin (YSA tarafında görüntü üzerinde bulunması gerekenler) parlaklık deđerlerinin her bir eđitim seti için ortalama parlaklık deđerleri hesaplanarak deđerinin istatistiđi çıkarılmıřtır. Çıkan istatistik sonucu her bir örnek seti için ortalama parlaklık deđerini tespit edilmiř ve örneklerin kendi parlaklık deđerleri ortalamalarının, buldukları eđitim seti ortalamasına çekilerek eđitime bařlanmasının daha verimli olacađı düşünölmüřtür. Örneklerin ortalama parlaklık deđerinin örnek seti ortalamasına eřit olması için ortalama farkı;

Ortalama Farkı = Eđitim Seti Parlaklık Ortalaması–Örneđin Parlaklık Ortalaması (15)

Formölüyle hesaplanmaktadır. Hesaplanan ortalama fark, örnekteki her pixel deđerine eklenir.

Eđitim seti oluřtururken örneđi maskelemek tasarlanan yapay sinir ađının ilgilneceđi veriyi azaltmakta ve böylece eđitim süresini kısaltabilmektedir. Yapılan çalıřma hücreler üzerinde olması ve hücrelerin farklı rotasyonlarda bulunması ve kenar bilgilerinin gerekliliđi nedeniyle sabit bir maske kullanma imkânı bu çalıřmada olmamıřtır. Bu nedenle örneđin tümü her hangi bir maske ile kırılmadan yapay sinir ađına verilmiřtir.

Eđitim setindeki örnekler 30x30 pixel ebatlarında alınarak tek boyutlu bir dizi řeklinde giriř kanmanı sayısı 900 elemana sahip olan ađa verilmiřtir. Gizli katman sayısı 1 ve bu katmanın 40 ve 50 adet eleman ile eđitimine farklı momentum ve öđrenme katsayıları için belirli iterasyonlarda ve her iterasyonda farklı bařlagıç ađırlıklarının atanmasıyla denenmiřtir.

3. SONUÇLAR

Çalışmada, görüntü üzerinde çeşitli ön işlemler gerçekleştirilerek, görüntü üzerindeki gürültü ve gereksiz bilgiler elimine edilmiştir.

Otsu eşikleme yöntemi kullanılarak, kenar bilgisi veya görüntünün kendisi ikili bilgiye dönüştürülmüştür. Elde edilen ikili bilgiden, hücre yapısının çembere benzerliğinden yararlanılarak, Hough dönüşümü ile görüntü üzerinde hücreleri çevreleyen çemberler araştırılmış ve hücreler tespit edilmiştir.

Arka plan renginden ayrılan ve ikili hale gelen görüntü üzerinde etiketleme işlemi gerçekleştirilerek, hücre olabilecek nesnelere ortamdaki yoğunluklarına göre tekrar bir yoğunluk eşikleme işlemine tabi tutularak aralarından gerçek hücrelerin seçilmesi için çaba gösterilmiştir.

Tüm eleme işlemlerinden sonra elde kalan nesnelere, dinamik yapıda geliştirilen çok katmanlı yapay sinir ağının eğitiminde kullanılarak farklı hücrelerin tanınması amaçlanmıştır.

Çalışmanın yapay sinir ağı tam olarak eğitilememiştir. Eğitim için farklı örnekler ve belirli bir süre gerekmektedir.

4. ÖNERİLER

Yapılan çalışmada bitişik hücrelerin ayrık ele alınması amacıyla süre kısıtlaması nedeniyle watershed yöntemi uygulanmadan önce farklı yumuşatma yöntemleri denenmelidir. İşaret konularak uygulanacak watershed yöntemi hücrenin arka plandan ve kendisine yapışık veya üstüste görüldüğü hücrelerden belirli sınırlar çerçevesinde ayrılmasını sağlayacaktır.

Üst üste binen şekillerden watershed yöntemiyle ayrılan parçaların kalan kısmı Hough dönüşümü yardımıyla tamamlanabilir. Böylece tamamlanan kısım orijinal resimden geri alınarak hücre hakkında karar vermek mümkün olacaktır.

Eşikleme sonucu arka plandan ayrılan görüntüler, etiketlendikten sonra, bir hücre boyutundan büyük olan her bir etiketli bölge kendi içinde tekrar eşiklenmeli ve hücre olabilecek parçalarına ayrılana kadar bu işlem rekürsif olarak tekrarlamalı ve tıkanacağı yerlerde farklı yöntemler de kullanabilmelidir.

Ağın eğitiminin tamamlanabilmesi için kendi kötü örneklerini seçebileceği bir yapıya dönüştürülebilir. Yapay sinir ağına sadece hücre görüntüleri dergıl bulunduu kare alanı içinde hücrenin dışında kalan alanlar bilgisi, ağırlık merkezi bilgisi ve kerner çizilerinin koordinatları da eğitim ve çeşit belrleme için kullanılabilir. Eğitim setinin oluşmasında az önce belirtilen verilerin farklı rotasyonlar için de belirtilebilir.


5. KAYNAKLAR

1. Kara S., Şener F., Okandan M. ve Yıldırım M., Patolojik Doku Örneklerinin Bilgisayar Tabanlı Analizi, Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 18-20 Haziran 2003, 246 s.
2. “William’s Haematology” 5th edition McGraw-Hill, 34-35 ss.
3. Hematology Atlas, 42-43 ss.
4. Hematology Atlas, ss. 44-46.
5. Ozcan O., Ders Planı, İç hastalıkları A.B.D., Periferik Yayma, 1999.
6. Dr. Sood R., Medical Laboratory Technology, 4th edition, Jaypee brothers, India, 2002.
7. Gonzalez R.C. ve Woods R.E., Digital image processing, Prentice Hall, 2002.
8. Boe S., Lonnestad T. ve Milvang O., XITE user’s manual, Image Processing Lab., Dept. Informatics, 1998.
9. Otsu N., A threshold selection method for gray-level histograms, IEEE Trans. Syst., Man, Cybern., vol. SMC-1, Jan 1979, 62-66 pp.
10. Torbjorn S. ve Eiletsen K., An Algorithm for Fast Adaptive Image Binarization With Applications in Radiotherapy Imaging, IEEE Transactions on Medical Imaging, Vol: 22, No: 1, Jan 2003.
11. Liao P.S., Chen T.S. ve Chung P.C., A Fast Algorithm for Multilevel Thresholding, Journal of Information Science and Engineering 17, 713-727, 2001.
12. Umbaugh S.E, Computer Vision and Image Processing: A Practical Approach Using C/++ Tools (BK /CD-ROM), Published by Prentice Hall Professional Technical Reference, First Edition, 1998, 51, 52.
13. A.K. Jain, Fundamentals of Digital Image Processing Enlewood Cliffs, NJ : Prentice Hall, 1989.
14. Rad A.A., Faez K. ve Qaragozlou N., Fast Circle Detection Using Gradient Pair Vectors, Proc. VIIth Digital Image Computing: Techniques and Applications, Sun C., Talbot H., Ourselin S. and Adriaansen T. (Eds.), 10-12 Dec. 2003, Sydney
15. www.volkansalma.com, 11/05/2006.


16. Duda, R. ve Hart, P., Use of the Hough Transform to Detect Lines and Curves in Pictures, Communications of the CM 15, 1975, 11-15 ss.
17. Gonzales R.C. ve Woods R.E., Digital Image Processing, Prentice Hall, 2002.
18. Şengür A., Türkoğlu İ. ve İnce M.C., Medikal İmgelerde Histogram Tabanlı Bölütleme Uygulamaları, 4 th International Advanced Technologies Symposium, September 28-30, 2005, Türkiye, Konya.
19. Mehra Pankaj Wah W Benjamin, Artifisal Neural Networks Concepts and Theory, IEEE Computer Society Press, Washington, 1992, s. 45.
20. Öztemel E., Yapay Sinir Ağları, sf 40, Papatya Yayıncılık, İstanbul, 2003.
21. Caudill Maureen, "Neural Network Primar Part 1" AI Expert, December 1987, s. 47.
22. H. Stern, Neural Networks in Applied Statistics, 1996.
23. Curram, S.P. ve Minger, J., Neural Networks, Decision Tree Induction and Discriminant Analysis: Embrical Comprasion, s. 441, 1994.
24. Curram, S.P. ve Minger, J., Neural Networks, Decision Tree Induction and Discriminant Analysis: Embrical.
25. Comprasion, 1994, s. 442.
26. Alabağ, Ç. ve Dengiz, B., Tabu Arama Algoritması ile Yapay Sinir Ağlarının Eğitimi, 2002.

6. EKLER


Ek 1. Kan Hücresi Şekilleri




A) Nötrofil




B) Band Nötrofil




C) Eosinofil



D) Bazofil



E) Monosit



F) Lenfosit

ÖZGEÇMİŐ

Tolga KARADENİZ, 1980 Trabzon doğumludur. Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliđi bölümünden 2002 yılında mezun olmuştur. 2002 güz yarıyılıının sonundan itibaren KTÜ Enformatik Bölümü'nde Öğretim görevlisi olarak görev yapmakta, Bilgi İşlem Dairesi ve Öğrenci İşleri Daire Başkanlığınca ihtiyaç duyulan birçok yazılım çalışmasında görev almaktadır.