



İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

130799

YÜKSEK LİSANS TEZİ

**BİYOMEDİKAL İŞARETLERİN MARKOV RASTGELE
ALANLARI KULLANILARAK İŞLENMESİ**

NİYAZİ KILIÇ

Biyomedikal Mühendisliği Anabilim Dalı

Danışman

Doç. Dr. Osman Nuri UÇAN


Haziran 2003

**T.C. YÜKSEK ÖĞRETİM KURULU
BİLİMSEL ARAŞTIRMALAR VE TEKNOLOJİ GELİŞTİRME BAKANLIĞI**

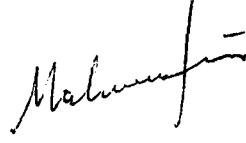
İSTANBUL

İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

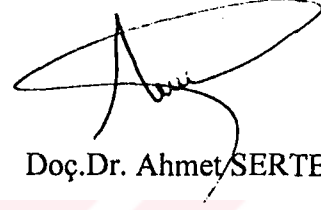
Bu çalışma 15/07/2003 tarihinde aşağıdaki jüri tarafından Biyomedikal Mühendisliği Anabilim Dalı Biyomedikal Mühendisliği programında Yüksek Lisans Tezi olarak kabul edilmiştir.



Doç.Dr. Osman/Nuri UÇAN
(Danışman)



Prof.Dr. Mahmut ÜN



Doç.Dr. Ahmet SERTBAŞ



Doç.Dr. Serhat ŞEKER



Y.Doç.Dr. Selçuk PAKER

ÖNSÖZ

Yüksek lisans öğrenimim ve tez çalışmam boyunca bana hep yardımcı olan ve yol gösteren hocam Sayın Doç. Dr. Osman Nuri Uçan'a, yardımlarından dolayı İstanbul Üniversitesi Bilgisayar Mühendisliği Araştırma Görevlisi Sayın Tolga Ensari'ye, Elektrik Elektronik Mühendisliği Araştırma Görevlisi Sayın Bahattin Karakaya'ya teşekkürlerimi sunarım. Ayrıca tez çalışmam boyunca bana destek olan ve sabır gösteren oda arkadaşım Araştırma Görevlisi Sayın Niyazi Odabaşoğlu'na ve her aşamadaki manevi desteklerinden dolayı aileme teşekkür ederim.

İstanbul, Haziran 2003

Niyazi KILIÇ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	I
İÇİNDEKİLER	II
ŞEKİL LİSTESİ	IV
ÖZET	V
SUMMARY	VI
BÖLÜM 1. GİRİŞ	1
BÖLÜM 2. MALZEME VE YÖNTEM	4
2.1 Markov Rastgele Alanları.	4
2.1.1 Gibbs ve Markov Rastgele Alanları.	6
2.1.1.1 Ayrık Gibbs Rastlantı Alanı.	8
2.1.1.2 Ayrık Markov Rastlantı Alanı	10
2.1.1.3 Geometrik Komşuluk Kavramı	11
2.1.2 Gibbs ve Markov Rastlantı Alan Modelleri	16
2.1.2.1 Gibbs Dağılımının Oluşturulması	17
2.1.2.1.1 Bölge Modeli	18
2.1.2.1.2 Bölütleme Problemi	19
2.1.2.1.3 Beyaz Gürültü Eklenmiş Bir Gürültü İçin MAP Bölütleme Algoritması	20
2.2 Markov Rastgele Alanları ile Görüntü İşleme	23
2.2.1 Gibbs Dağılım Parametrelerinin Elde Edilmesi	23
2.2.2 Markov Rastgele Alan Modellenmesi	27
2.3 Yapay Sinir ağları ve Hücresel Yapay Sinir Ağları	29
2.3.1 Yapay Sinir Ağları	29
2.3.1.1 Yapay Sinir Ağlarının Tanımı ve Özellikleri	31
2.3.1.2 Matematiksel Nöron Modeli.	34
2.3.1.3 Aktivasyon Fonksiyonları	35
2.3.1.4 Yapay Sinir Ağ Modelleri	37
2.3.1.5 Yapay Sinir Ağ Modellerinde Öğrenme	38
2.3.2 Hücresel Yapay Sinir Ağları	38
2.3.2.1 Hücre Yapıları	40
2.3.2.2 Hücresel Yapay Sinir Ağlarında Komşuluk İlişkisi	41
2.3.2.3 Hücresel Yapay Sinir Ağlarının Devresel Gösterimi	42
2.3.2.4 Diferansiyel Denklemlerin Fark Denklemleri Olarak Gösterilmesi	45
2.3.2.5 Hücresel Yapay Sinir Ağlarında Kararlılık	46
2.3.2.5.1 Hücresel Yapay Sinir Ağlarında Sürekli Zaman Analizi	48
2.3.2.6 Hücresel Yapay Sinir Ağlarında Öğrenme	49
2.3.2.6.1 RPLA Öğrenme Algoritması	50
2.3.2.7 Hücresel Yapay Sinir Ağlarında Konvülsiyon İlişkisi	54
2.3.2.8 Hücresel Yapay Sinir Ağlarında Yayılım Özelliği	55
2.3.3 Markov Rastgele Alanları ve Hücresel Yapay Sinir Ağları Modellenmesi	56

	<u>Sayfa No</u>
BÖLÜM 3. BULGULAR	58
3.1 Markov Rastgele Alanları ile Modellenen Biyomedikal Görüntülerin Benzetim Sonuçları	58
3.2 MRA-HYSA Yapısı ile Modellenen Biyomedikal Görüntülerin Benzetim Sonuçları	63
TARTIŞMA VE SONUÇ	65
KAYNAKLAR	67
ÖZGEÇMİŞ	71



ŞEKİL LİSTESİ

	<u>Sayfa No</u>	
Şekil 2.1	Klik Çeşitleri	9-10
Şekil 2.2	Hiyerarşik olarak düzenlenmiş η^m komşuluk sistemi	12
Şekil 2.3	S ve İkinci dereceden komşuları	24
Şekil 2.4	Tek gizli katmanlı yapay sinir ağ modeli	32
Şekil 2.5	Nöron yapısı	34
Şekil 2.6	Aktivasyon fonksiyonları	35
Şekil 2.7	Farklı λ değerleri için (2.56) denklemi ile tanımlanan fonksiyonun görünümü	36
Şekil 2.8	Tek katmanlı ileri beslemeli ağ modeli	37
Şekil 2.9	3×3 boyutunda bir hücresel yapay sinir ağı gösterimi	39
Şekil 2.10	Bir hücrenin dinamik yapısı	40
Şekil 2.11	Hücresel yapay sinir ağlarında komşuluk	41
Şekil 2.12	$r=1$ komşuluğunda altıgen yapıya sahip hücresel yapay sinir ağı	42
Şekil 2.13	Bir hücre yapısının devresel olarak gösterilmesi	42
Şekil 2.14	Parça-parça doğrusal çıkış karakteristiği	43
Şekil 2.15	MRA-HYSA modeli blok şeması	57
Şekil 3.1	Kan hücresi görüntüsü	58
Şekil 3.2	Enamel hücresi görüntüsü	59
Şekil 3.3	Bakteri hücresi görüntüsü	60
Şekil 3.4	Kaburga görüntüsü	61
Şekil 3.5	Bonemarr görüntüsü	62
Şekil 3.6	MRA-HYSA yapısı için test-1 görüntüsü	63
Şekil 3.7	MRA-HYSA yapısı için test-2 görüntüsü	64

ÖZET

BİYOMEDİKAL İŞARETLERİN MARKOV RASTGELE ALANLARI KULLANILARAK İŞLENMESİ

Bu çalışmada Markov rastgele alanları ve Hücresel yapay sinir ağları kullanılarak oluşturulan görüntü işleme algoritmaları ele alınmıştır. Markov rastgele alanları ile modellenen biyomedikal görüntülerin işlenmesi konusunda çalışmalar yapılmış ve sonuçlar değerlendirilmiştir.

Bu uygulamaların yapılabilmesi için teorik incelemeler yapılmıştır. İkinci bölümde rastgele alan modellerinin görüntü analizindeki günümüz problemleri açısından nasıl bir uygulamaya sahip olduğu açıklanmaktadır. Rastgele alan modelleri, bölütleme ve yeniden oluşturma gibi piksel etkileme problemlerine uzamsal içerikte bir girişe olanak tanımaktadır. Rastgele alan modelleri ayrıca görüntü tanıma ve görüntü üretme, tanımlama ve görüntüleri kesitlemek için gerekli algoritmaların oluşmasına olanak sağlar. Literatürde kaydedilmiş bazı etkileyici modeller baz alınmış görüntü restorasyon ve dokuma kesitleme sonuçlarına rağmen MRA modellerinin tariflenmesi, gürültü işlemlerinin tasarlanması, performans değerlendirilmesi, parametrelerin karşılaştırılması, faz geçiş fenomenleri ve alternatif prosedürlerin karşılaştırılmalı analizleri gibi bir çok temel konu keşfedilmemiş olarak günümüze kadar süregelmiştir. Rastge alan modellerinin literatürü ileriye yönelik umut verici sinyaller vermektedir. Fakat uygulamalar için gerekli olan verimli algoritmalarla beraber bu konular için daha iyi bir matematiksel anlayış ve felsefe gerekmektedir.

Üçüncü bölümde Hücresel yapay sinir ağları ele alınmıştır. Hücresel yapay sinir ağlarının temel yapısı irdelenmiş ve karakteri incelenmiştir. Hücresel yapay sinir ağlarının görüntü işleme uygulamaları üzerinde durulmuştur. Ayrıca Markov rastgele alanları ile Hücresel yapay sinir ağları beraber ele alınmış ve birleşik bir algoritma ortaya konulmuştur. Bu algoritmalar ile ilgili bazı uygulamalar yapılmış ve sonuçlar üzerine değerlendirmeler sunulmuştur.

Son bölümde ise sonuçlar değerlendirilmiş hangi koşullar altında hangi çözümlerin uygun olacağı tartışılmıştır.

SUMMARY

BIOMEDICAL SIGNAL PROCESSING USING MARKOV RANDOM FIELDS

In this thesis we deal with two-dimensional digital image that can be represented by $N_1 \times N_2$ matrix or lattice, whose elements (called pixel) can have values from 0 up to $G-1$ corresponding to the brightness levels (gray levels). The gray level of a pixel is highly dependent on its geometric neighboring pixels, but nearly independent of remote pixels.

Markov Random Fields (MRF) and Cellular Neural Networks (CNN) have been found to rich models for various areas in image analysis according to the dependency among pixels in spatial neighborhoods. Thus, the classical problem of texture synthesis, texture classification, image segmentation, image restoration and image compression have been studying using with MRF and CNN.

The second chapter describes MRF. MRF models assume that the intensity at each pixel in an image depends on its "neighboring pixels" but is independent of other pixels. An image is viewed as a colored lattice, because of the natural coincidence between the local dependency of a model and the local dependency of neighboring pixels. MRF is a probability space with measure, defined on the sample space consisting of all possible colored lattice. Markov random fields have been extensively used for modeling images.

In third chapter, a unified review of the CNN paradigm is attempted. First of all, general theoretical framework is stated, followed by the description of particular models proposed in literature and comparison with other neural networks and parallel computing paradigms. Theory of such systems, especially the issue of stability, is then studied by listing main results available. Applications, design and learning flow are explained.

And also, we propose a new scheme and combined algorithm MRF and CNN together. Some applications with this algorithm are done for various areas.

1. GİRİŞ

Günlük yaşamda çeşitli alanlarda elimizde bulunan görüntülere bakarak kararlar vermemiz gerekmektedir. Örneğin, tıbbi alanda, çekilen bir röntgen filmine bakarak hastalığı teşhis etmek; bir havaalanında radar sinyalleri ile hava trafiğini kontrol etmek; havadan çekilen resimleri kullanarak yeraltındaki petrol rezervlerini veya maden kaynaklarını bulmak. Bu ve bunlar gibi birbirinden farklı olayları görüntü analizi adı altında toplamak mümkündür.

Görüntü analizi, bilgisayar yardımı ile resimlerin analizi ve onlar üzerinde çeşitli işlemler yapmak olarak düşünülebilir. Görüntü formu oluşturma (image formation), iyileştirme (enhancement), yeniden oluşturma (reconstruction), bölütleme (segmentation), kodlama ve sıkıştırma (coding and compression), doku analizi (texture analysis), şekil analizi (shape analysis), gösterim (representation), eşleme (matching), tanımlama (description) ve tanıma (recognition) görüntü analizinin en önemli alt bölümlerini oluşturmaktadır. Görüntü analizinde veri yapısı ve amaç çok önemli olduğundan görüntü analizinde izlenebilecek standart bir yöntem yoktur[1-4].

Bu tez çalışmasında 2-boyutlu, her bir elemanı (pixel), G seviyeli 0 ile G-1 değerleri arasında bir renge (gray level), sahip NxN'lik bir kafes (lattice) ile gösterilebilen sayısal görüntülerle ilgilenilmektedir. Bu sayısal görüntülerde, kafes üzerindeki bir noktanın renginin onun geometrik komşularından oluşan noktaların renklerine oldukça bağımlı, diğer noktalara ise bağımlı olmadığı kabul edilmektedir[5].

ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜZ YILLIK KONGRESİ

Piksel etiketleme sorunu, kötü konumlanmış (*ill-posed*) bir sorundur; diğer bir deyişle, eldeki veriler, problemi tek bir çözüme ulaştırmaya yeterli değildir. Problemin iyi konumlanmış hale getirmek amacıyla, belirli kısıtlar kullanılır; bu yöntem *düzenleştirme (regularization)* yöntemi adı verilir[5]. Özellikle bölütleme ve gruplama problemlerinde, sıralanan kısıtlar öne sürülmüştür. Komşu piksellerin aynı bölgeye/sınıfa ait olma olasılığı daha yüksektir, birbaşına (isolated) ayrıtların olabilirliği düşüktür ve yüzeyler düzgün dağılmıştır.

Bilgisayarla görü araştırmalarının gelişimi başlangıcından bu yana yaklaşımların sistematik incelenmesi yönünde olmuştur. Bu çalışmalarda araştırmacılar görü probleminin çözümü olarak eniyileme ilkeleri üzerinde durulmasının gerektiği ve imgeler için görsel bilginin anlaşılmasında bağlamsal (contextual) kısıtlamaların gerekli olduğu sonuçlarına varmışlardır. Bu sonuçları da bağlamsal kısıtlamalar altında bir eniyileme kriterinin nasıl tanımlanacağı ve tanımlanan kriterin çözümünün nasıl bulunacağı sorunları izlemiştir.

Markov Rastgele Alan (MRA) teorisi olasılık teorisinin bir kolu olarak bağlamsal kısıtlamaların betimlenmesi ve etkileşen özneliklerin olası dağılımının türetilmesinde bir temel teşkil etmiştir. MRA teorisi kestirim ve karar verme yöntemlerinin birleşimiyle en büyük sonlu olasılık (Maximum a posteriori: MAP) kavramı benzeri eniyileme kriterlerinin türetilmesi için sistematik bir yaklaşım sağlamıştır. Ayrıca kullanılan bu çatı rasyonel prensipleri kullanan bir çok görüş problemi için sistematik algoritma geliştirilmesine olanak tanıdığından dolayı da son yıllarda bilgisayarla görüş problemlerinin modellenmesinde MRA'nın kullanılması gittikçe artan bir ilgi görmektedir.

MRA teorisi imge pikselleri gibi uzamsal ilişkili öznelikleri olan bağlamsal nesnelere modellenmesinde tutarlı ve elverişli bir yol sağlar. Bu ise nesnelere aralarındaki ortak etkinin MRA olasılıkları kullanılarak sıkı bir şekilde betimlenmesiyle başarılıdır. MRA modelinin pratikte kullanımı, MRA'ları ve Gibbs dağılımları arasındaki eşdeğerliğin kurulması ve MRA'ların ortak dağılımın geliştirilmesiyle sağlanmıştır. Bu kullanımda Bayes çatısında imge analizi için görsel problemlerin modellenmesinde matematiksel olarak sağlam olduğu kadar kolay işlenebilir bir vasıta oluşturur. Hesaplama açısından bakılacak olursa MRA'ların yerel özellikleri, yerel ve paralel tarzda uygulanabilecek algoritmalara yol gösterir. Ayrıca MRA teorisi çok çözünürlüklü hesaplamalar içinde bir temel teşkil eder.

Bu sebeplerden dolayı MRA görüş probleminin bütün seviyelerinde geniş bir şekilde kullanılmıştır. Fakat çoğunlukla düşük seviyeli uygulamalar modellenmiştir. Bunları imge onarımı ve bölütleme, yüzey yeniden yapılanması, kenar bulma, doku analizi, görsel akış, veri birleştirme, görsel birleştirme ve algısal organizasyon olarak sayabiliriz. MRA'ların nesne eşleme ve tanıma gibi yüksek seviyeli görüş çalışmalarında son yıllarda kullanımı yaygınlaşmıştır.

Teorik olarak son derece sağlam temeller üzerine oturtulmuş olmasına karşın MRA modellerinin de önemli götürüleri vardır. MRA modelinde MAP kestiriminin kullanımı imgedeki sınıfların kestiriminin en az yanlış sayıda sınıflandırılmış piksel kalması prensibine göre olduğundan, çözüme yoğun hesaplamalardan sonra ulaşılabilir. Yüksek çözünürlüklü imgelede az sayıda pikselin yanlış sınıflandırılması imgenin kalitesini çok fazla düşürmez. Bu sebeple MRA ile modellenen yüksek çözünürlüklü imgede gereksiz yere çok yoğun işlemler yapılır. Ayrıca MRA model parametrelerinin kestirimi için henüz etkin bir model geliştirilememiştir.

İki boyutlu bir dizi oluşturacak şekilde sıralanmış hücrelerden oluşan Hücresel yapay sinir ağlarında her hücre bilinen yapay sinir ağlarının aksine yakın komşuluğundaki

hücrelerle bağlantı halindedir. Gerek bu durum ve gerekse hücreler arasındaki bağlantı ağırlık katsayılarının genelde çalışılan düzlemde değişmemesi durumu hücrel yapay sinir ağlarını ortaya atıldıkları 1988 yılından itibaren özellikle görüntü işleme konularında oldukça geniş kullanımına imkan sağlamıştır. Böylece klasik yapay sinir ağlarına kıyasla bir görüntüden istenilen amaca yönelik başka bir görüntünün elde edilmesi işlemi daha az katsayı kullanılarak gerçekleştirilebilmektedir. İkinci bölüm üçüncü kısımda Hücrel Sinir Ağlarına yer verilmiş; Hücrel sinir ağ yapıları, avantajları, uygulama alanları geniş bir şekilde belirtilmiştir.

Gibbs kriterinin hesap yoğunluğu çok olduğundan dolayı modelde bazı yaklaşımlara gidilmiştir. Markov Rastgele Alanları ile Hücrel Yapay Sinir Ağları kaskad bağlanarak MRA-HYSA modeli oluşturulmuştur. Bu yeni modelle Markov rastgele alanlarının gürültü temizlemede ki başarısı ile Hücrel yapay sinir ağlarının boşluk doldurma ve hesap süresinin kısalığından faydalanılmıştır[6]. Bu yeni yapı ile ilgili gerekli blok şemalar gösterilmiş ve uygulama sonuçları üzerine değerlendirmeler yapılmıştır.

Bulgular bölümünde biyomedikal görüntülerin Markov Rastgele Alanları ve MRA-HYSA modeli ile gerçekleştirilen benzetim sonuçları verilmiştir. Son bölümünde ise ele alınan konularla ilgili genel bir değerlendirme yapılmıştır.

2. MALZEME VE YÖNTEM

2.1. MARKOV RASTGELE ALANLARI

Bilgisayar destekli görüntü işleme literatüründe görüntüyü modellemek ve işlemek için kullanılan istatistiksel yöntemlere karşı özellikle son yıllarda artan bir ilgi vardır. Bu tür çalışmaların bir çoğu gürültülü görüntülerin ayrıştırılması ve yenilenmesi problemlerinde çokça kullanılan Markov rastgele alan modeli uygulamaları doğrultusunda gerçekleştirilmiştir.

Geman ve Geman [7], Cohen ve Cooper [8] tarafından yazılan raporlarda ve Derin ve Elliott [9-11] tarafından yapılan çalışmalarda MRA modelini karakterize etmek için kullanılan Gibbs Dağılımı (GD) ilk olarak Ising tarafından ferromanyetik malzemelerdeki moleküler etkileşimi modellemek için kullanılmış ve işleme algoritmasını daha kolay kontrol edilebilir ve daha güvenilir hale getirdiği görülmüştür.

Görüntü analizinde, uzamsal komşuluklar içindeki noktalar arasındaki bağımlılıktan dolayı, Markov rastgele alanlarının çeşitli modelleri bulunmuştur [5]. Böylece, görüntü analizinin klasik problemleri olan doku sentezleme [1-2] doku sınıflandırma [3], görüntü bölütleme, görüntü yenileme [4],[10] ve görüntü sıkıştırma konularında Markov rastgele alanları ile büyük ilerlemeler kaydedilmiştir.

Görüntü modeli kurmanın temel bir kuralı yoktur. Ancak görüntünün bazı özelliklerinden yola çıkarak model kurulabilir. Markov rastgele alan modellerinde, görüntü üzerindeki her bir noktanın parlaklığı onun komşu noktalarına bağımlı, diğer noktalardan kısmen bağımlı olduğu kabul edilmiştir. Görüntü kafes üzerindeki renklerin bileşiminden oluşan bir renk kümesi olarak düşünülebilir. Bir Markov rastgele alanı, bir kafesin tüm olası gerçeklemelerinden oluşan örnek uzayı üzerinde tanımlanan pozitiflik, Markov özelliği ve homojenliği sağlayan olasılık ölçüsüne sahip bir olasılık uzayıdır [5]. Markov rastgele alanları görüntü modellemede yaygın olarak kullanılmaktadır [1-3]. Derin ve Kelly [12] görüntü analizinde kullanılan Markov tipli rastlantı alanlarının geniş bir özetini yayınlamışlardır.

Bir MRA modeli kurmada iki özellik gözönüne alınır. MRA, bir sınıfa ait görüntünün özellikleri ile eşleşmeli ve matematiksel bir forma sokulabilmelidir. MRA ile üretilen görüntülerde, görüntüyü oluşturan noktaların değerleri tam sayı ise görüntü ayrık,

değilse sürekli dir. Örneğ in, auto-binomial MRA [5] ayrı k bir MRA, auto-normal MRA [5] da bir sürekli MRA'dır. Literatürde yapılan çalıřmalar, ayrı k MRA ların sayısal dokulara, sürekli MRA'lardan daha yatkın olduğ unu fakat matematiksel bir forma sokmanın sürekli MRA'lardan daha zor olduğ unu göstermektedir.

Görüntü analizinin, özellikle MRA'larının kullanıldıđı, bazı temel işlemlerini kısaca tanı tacak olursak; klasik sorunlarından biri olan doku sınıflandırma problemi ařağ ıdaki gibi ifade edilebilir. i doku sınıfına ait, K seviyeli, $1 \leq i \leq K$, gibi doku örnekleri verildiğ inde bu örneklerden dokusal özellikler çıkarmak ve bu özelliklere dayanan bir karar kuralı bulmak gerekir. Çünkü K sınıftan hangisine ait olduğ u bilinmeyen dokuyu dođ ru bir řekilde sınıflandırabilmek için böyle bir karar kuralı gerekmektedir.

Basit ve kolayca hesaplanabilen bir yöntem istenmesine rağ men, sınıflandırma ve görüntü tanı mada seçilecek dokusal özellikler için genel bir yol yoktur. Dokusal özellikler 'gray level co-occurrence matrices' 'gray level run lengths' [13], 'gray level differences' [13], 'Fourier power spectra' [13], 'spatial filtering' [14] ve 'Markov random field model fitting' [3] yöntemlerinden biri kullanılarak kolayca elde edilebilirler. Tamura [15], iri tanelilik, zıtlık, dođ rultululuk, çizgililik, düzenlilik ve pürüzlülük olmak üzere görsel algılamaya dayalı altı dokusal özellik önermiştir.

Bir sınıflayıcı, dokusal özellikleri kullanarak, bilinmeyen bir dokuyu, bilinen sınıflardan birine atayan bir karar kuralından başka bir şey değildir. Görüntü tanı mada, 'quadratic' ve 'Fisher's Linear Classifier' yöntemleri yaygın olarak kullanılmaktadır[15]. Sınıflayıcı, deneme örnekleri ve özellik sayısı arasındaki ilişki gözönüne alınarak tasarlanmalıdır. Literatürde genellikle özellik sayısının dört veya beř katı fazla örnek kullanılır. Sınıflandırma hata olasılığ ı, sınıflayıcının kullanılabilirlik ölçütü olarak kabul edilir ve doku sınıflandırmada bu deđer, dokusal özelliklerin geçerliliğ inin bir ölçütü olarak da kullanılır.

Bölütlemenin amacı, görüntüyü anlamlı parçalara ayırmaktır. Bu anlamlı parçalara ayırmanın tanı mı günümüzde hala üzerinde düşünölen bir problemdir. Literatürde, MRA üzerine bölütleme algoritmaları araştırılmıř ve geliřtirilmiştir [4],[7],[16-17]. Bölütleme problemi ř u řekilde ifade edilebilir. Verilen bir görüntü, y olarak kabul edilirse, belirlenmiř bir kriterle bu y görüntüsü içerisindeki noktalardan bir x gerç eklemesi bulunmalıdır. Bunun için temel iki yaklařım vardır. 'Iterative pixel labeling approach' olarak bilinen bu yöntemde kullanılan kriter bir MAP olasılığ ıdır. Amaç, bütün olası x 'ler iç inden (2.24) denkleminin deđerini maximum yapan x 'i bulmaktır [7]. 'Bölge sınıflandırma yaklařımı' yönteminde ise görüntü birkaç bölgeye ayrılır ve her bölge, parametreleri bilinen bir tek MRA modelinin bir gerç eklemesi veya iki MRA modelinin birleřimi olarak düşünölr. Derin, bu yöntem için bir

bölütleme algoritması geliştirmiştir [16-17]. Bölütlemenin bir başka amacı da, görüntü içindeki bölgeleri otomatik olarak ayırt edebilmektir.

Görüntü yenilemedeki amaç ise, herhangi bir dış etki ile (örneğin, gürültü) bozulmuş görüntüleri, iyileştirmek veya aslına uygun olarak yeniden oluşturmaktır. Genellikle, uygulama alanları uzay ve biyomedikal görüntüler üzerinedir.

2.1.1. GIBBS ve MARKOV RASTGELE ALANLARI

İki boyutlu Markov rastgele alan yaklaşımına bağlı olan stokastik modeller, deneme-yanılma işlemi gerçekleştirilemeyen birçok pratik gelişimine önayak olmuştur [5],[17]. Rastgele Alan yaklaşımı istatistiksel bağımlılığa zorlayan, piksel şiddeti gibi ilgilenilen hedefi temsil eden rastgele değişkenlere bağlı olan ortak dağılımdır.

Modellemenin amacı verileri üreten olayın doğasını anlayabilmek için birkaç parametreyi ele alarak verilerin karakterini yakalamaktır[18]. Veri işleme ve modelleme için son birkaç yılda istatistiksel tekniklerin kullanımında artan bir ilgi vardır. R.C.Dubes, 1989, S.Geman, D.Geman, 1984, H.Derin. A.H.Elliot,1987 tarafından yazılan raporlarda Markov rastgele alanını karakterize etmek için Gibbs Dağılımı kullanılmıştır. Gibbs dağılımının orijini istatistiksel mekanik ve fiziğe dayanır. E.Ising 1925'te, ferromanyetik malzemelerin manyetik özelliklerini açıklayan, şimdi Ising modeli olarak bilinen özel bir Gibbs dağılımı kullanmıştır.

Herhangi bir gürültü ile bozulmamış bir görüntü düşünüldüğünde, bu görüntü üzerindeki bir noktanın parlaklığının onun çevresindeki noktaların parlaklıklarına oldukça bağımlı olacağı rahatça söylenebilir. Bu bölümde, Gibbs rastlantı alanları ve Markov rastlantı alanları kullanılarak, bu bağımlılığın açık bir şekilde modellenmesi ve tez boyunca kullanılacak teorik tanımlar açıklanacaktır. GRA ve MRA görüntülerinin modellenmesinde karşımıza iki sorun çıkmaktadır. Bunlar GRA veya MRA yı örnekleme ve parametre değer biçimidir. Gibbs ve Markov Rastgele Alanları ile görüntü modellemede kullanacağımız kafes,(i,j) noktasında L, $N_1 \times N_2$ boyutlu noktalardan oluşan bir alandır.

$$L = \{ (i,j) \mid 1 \leq i \leq N_1, 1 \leq j \leq N_2 \} \quad (2.1)$$

Bir rastgele alan modelinde genellikle kafes üzerindeki her bir nokta bir renge karşı gelmekte ve bu renk değerini gösteren $X(i,j)$, bir rastlantı değişkeni olarak kabul edilmektedir. $X(i,j)$ ile de bu rastlantı değişkeninin aldığı renk değeri gösterilmektedir. Anlatımda kolaylık olması için bu tez çalışmasında aşağıdaki notasyon değişimi uygulanarak rastlantı değişkeni X_t ile gösterilecektir.

$$t = j + N_1 (i - 1) \quad (2.2)$$

Eğer görüntü gri seviyelerinden oluşan ayrık bir resim ise kafes üzerinde bulunan noktalara renk değerleri atama, sonlu bir küme olan $A = \{ 0, 1, 2, \dots, G-1 \}$ kümesinden yapılmaktadır. Sürekli bir resim ise A kümesi renk değerlerinden oluşan gerçel bir çizgiyi göstermektedir. (G en yüksek renk değeridir, iki-renkli görüntüler için $G=2$ alınır). Bizim çalışmalarımızda tüm renklerin gri seviyelerinden oluştuğu ayrık görüntüler ele alınacaktır.

(2.2)'deki gösterimle noktalar satır satır birbirinin peşine dizildiği varsayılmakta ve noktalar 1'den $N_1 \times N_2$ 'ye kadar numaralanmaktadır. Yani, $M = N_1 \times N_2$ dersek,

$$t \in L = \{ 1, 2, 3, \dots, M \} \quad (2.3)$$

$N_1 \times N_2$ boyutlu her bir noktası bir renk değerine sahip kafesi, Rastlantı Vektörü $\mathbf{X} = \{ X_1, X_2, \dots, X_M \}$ olarak göstermek olasıdır ve bu rastlantı vektörü bir görüntüyü (gerçeklemeyi) ifade etmektedir.

Matematiksel anlamda bir rastlantı alanı şu üçlüden ibarettir;

$$\langle \Omega, \Phi, P \rangle \quad (2.4)$$

Ω , kafes üzerindeki noktaların renklerinden oluşan örnek uzayını, Φ bu örnek uzayındaki Borel alt kümesinin tümünü ve P ise olasılık değerini göstermektedir. Yani,

$$\Omega = \{ (X_1, X_2, \dots, X_M) \mid X_t \in A \forall t \in L \}. \quad (2.5)$$

2.1.1.1. Ayrık Gibbs Rastlantı Alanı

Ayrık Gibbs rastgele alanı, Gibbs dağılımı kullanılarak, aşağıdaki olasılık yoğunluk işlevi ile tanımlanabilir. Bu alan ile görüntüye ait bütünsel özellikleri modellemek olasıdır.

$$P(X = x) = e^{-U(x)/Z},$$

$$Z = \sum_{y \in \Omega} e^{-U(y)},$$

Burada, $U(x)$ enerji işlevini, normalize sabiti Z ise bölümlenme işlevini göstermektedir. Bu aşamada bazı tanımlamalar yapmamız gerekmektedir.

Eğer $P(X_t = u \mid X_s = v) = P(X_t = u) \forall u, v$ ise, kafes üzerindeki s noktası t noktasının bir olasılıksal komşusu değildir.

Diğer bir deyişle, eğer $P(X_t = u \mid X_s = v, t = s) = P(X_t = u \mid X_s = v)$ ise s noktası t noktasının bir olasılıksal komşusudur.

Klik (clique), kafes üzerindeki bir noktanın olasılıksal komşuları ile oluşturduğu bütün ikili, üçlü, dördü vs. nokta çiftlerinin kümesidir. Kafes üzerindeki her bir nokta da birer kliktir.

η_i , i noktasını içeren kliklerin kümesi olsun. Bu durumda sıralanmış η_i 'ler kümesi $\{\eta_1, \eta_2, \dots, \eta_M\}$ bir Komşuluk Sistemini oluşturur. Bir komşuluk sistemindeki tüm kliklerin kümesine η diyelim. $V_c(x)$, η kümesi içindeki kliklerin işlevi olsun. Bu durumda yukarıda tanımladığımız enerji işlevi, $U(x)$, klik işlevlerinin toplamı

olarak ifade edilebilir. Klik işlevi, potansiyel işlevi olarak da bilinir ve işlevin aldığı değer, c numaralı kliki oluşturan noktaların renklerine bağlıdır.

$$U(x) = \sum_{c \in Q} V_c(x)$$


$$\eta = \{ \eta_{ij} : (i,j) \in L, \eta_{ij} \subseteq L \}, \quad (2.7)$$

(i,j) piksel noktasının komşuluğu η_{ij} olduğu takdirde (2.7) eşitliği L üzerinde bir komşuluk sistemidir öyle ki:


$$(i,j) \notin \eta_{ij}$$

Eğer $(k,l) \in \eta_{ij}$ ise herhangi bir $(i,j) \in L$, için $(i,j) \in \eta_{ij}$ 'dir.


(L, η) görüntü kümesi-komşuluk çiftinin tüm klikler toplam kümesi $C=C(L, \eta)$ olarak gösterilir. η_1 ve η_2 'yi içeren klik çeşitleri Şekil 2.1'de gösterilmiştir.




a) η_1 komşuluk sistemi,



b) η_1 'deki klik çeşitleri,



c) η_2 komşuluk sistemi,



d) η_2 'deki klik çeşitleri

Şekil 2.2. Klik çeşitleri

2.1.1.2. Ayrık Markov Rastlantı Alanı

Gibbs Rastlantı Alanının, kafes üzerindeki tüm noktaların renklerinden oluşan bir görüntünün bütün özellikleri ile tanımlandığını belirttik. Markov Rastlantı Alanı ise bu görüntünün sadece yerel özellikleri ile tanımlanan bir rastlantı alanıdır. Eğer komşuluk sisteminin geçerli olduğu bir rastlantı alan aşağıdaki şartları sağlıyorsa, Markov Rastlantı Alanı'dır.

a) Pozitiflik : $P(X=x) > 0$ bütün $x \in \Omega$.

b) Markov Özelliği : Bütün $t \in S$ için,

$$P(X_t=x_t | X_1=x_1, X_2=x_2, \dots, X_{t-1}=x_{t-1}, X_{t+1}=x_{t+1}, \dots, X_M=x_M) = P(X_t=x_t | \forall X_r=x_r, r \in N_t), \quad (2.8)$$

N_t , t noktasına ait komşuların kümesini göstermektedir. Ufak bir uyarılama ile,

$$P(X_t=x_t | \forall X_r=x_r, r \in N_t) = P(x_t | R_t) \quad (2.9)$$

şeklinde yazılabilir.

c)Homojenlik : $P(x_t | R_t)$ koşullu olasılığı sadece t noktasının değerine bağımlı değil komşu noktaların renk değerlerine de bağlıdır.

Bölüm 2.1.2.1 ye 2.1.2.2 den anlaşılacağı gibi, belirlenmiş klik işlevleri ile bütünsel, belirlenmiş koşullu olasılıklar ile de yerel özellikleri modellemek olasıdır.

Besag [5]'de tanıtı bulunan, belirlenmiş bir komşuluk sisteminde, her MRA için tek bir GRA ve her GRA için de tek bir MRA bulunmaktadır. Bu teorem, bileşke olasılık değerine (2.6) veya yerel koşullu olasılığa (2.8) denklemlerine dayalı bir rastlantı alanı tanımlayabileceğimizi ifade etmektedir. Anlaşılacağı gibi GRA ve MRA modelleri aynı komşuluk sistemi söz konusu ise birbirlerine eşdeğer olacaktır. Aksi halde her MRA nın bir GRA ya veya her GRA nın bir MRA ya eşdeğer olduğunu söylememiz doğru değildir.

2.1.1.3.Geometrik Komşuluk Kavramı

Görüntü analizinde kullanılan genel komşuluk sisteminde, komşuluk kavramı çok önemlidir. Bu komşuluk derecesi o noktaya ait komşu noktaların sayısını bildiren bir ölçüttür [5].

Modellemede kullanılan komşuluk sisteminin hiyerarşik sırası aşağıdaki gibidir.


$$\eta^1, \eta^2, \dots, \eta^m = \{n_{ij}^m\}$$

$$\eta^2 = \{\eta_{ij}^2\} : (i,j) \text{ pikseli komşuluğundaki 8 pikseli içerir.}$$

Komşuluk yapısı Şekil 2.1 ve Şekil 2.2'de gösterilmiştir. η^m komşuluk sistemi, m'inci dereceden komşuluk sistemi olarak adlandırılır.

c olarak gösterilen (L, η) komşuluk sistemi ile ilgili klikler, L 'nin bir alt kümesidir öyle ki:

- c , tek bir pikseli içerir ya da
- $(i,j) \neq (k,l)$ için, $(i,j) \in c$ ve $(k,l) \in c$, $(i,j) \in \eta_{kl}$ demektir.



Şekil 2.2. Hiyerarşik olarak düzenlenmiş η^m komşuluk sistemi

$$\eta_m = \{ \eta_{ij}^m \}$$

$$\eta_{ij}^m = \{ k : k \leq m \}$$

Gibbs Dağılımı temelde bir üstel dağılımdır. (2.6) eşitliğinden de anlaşılacağı gibi $X=x$ 'in görüntü içerisinde bulunma olasılığı, x 'in kendisine bağlı değil de x 'in içinde bulunduğu komşuluk sisteminin eksponansiyel enerji dağılımının görüntü kümesi içerisinde bulunma olasılığına eşittir.

Klik potansiyeli $V_c(x)$ 'i doğru seçerek çeşitli hem ayrık hem de sürekli rastgele alan dağılımları Gibbs Dağılımı ile formülize edilebilir. J.Besag, 1974, Markov Rastgele Alanı ile Gibbs Rastgele Alanı arasında birebir ilişki olduğunu ispatlamıştır. Böylece, herhangi bir rastgele alan, Markov Rastgele Alanı olarak ve dolayısıyla yeterli derecede geniş komşuluk sistemi ile Gibbs Rastgele Alanı olarak düşünülebilir. Yapılan birçok deney sonucunda birinci ve ikinci komşuluklar kullanılarak bile çok iyi sonuçlar alındığı görülmüştür.

Varsayalım ki X rastgele alanı, değerlerini $Q = \{ q_1, q_2, \dots, q_M \}$ kümesinden alan M değerli X_{ij} ayrık değişkenlerinden oluşsun. Gibbs Dağılımını tanımlamak için 3 parametre tanımlamak gerekmektedir. Bunlar; Komşuluk sistemi, Komşuluk sisteminin klik yapısı ve $V_c(x)$ klik potansiyelidir.

Rastgele alanın homojen olduğunu düşünürsek o zaman klik potansiyeli, klik çeşitlerine ve kliklerdeki piksel değerlerine bağlı olup klik'in görüntü içerisindeki yerine bağlı olmaz. Dağılımı η^2 ikinci dereceden komşuluk sistemine bağlı olarak tanımlayalım. O halde η^2 'ye göre klik potansiyelleri aşağıdaki şekilde tanımlanır, görüldüğü gibi tek pikseli klikler hariç her bir klik tipine ayrı bir parametre atanmıştır.

İkililer için;

$$[\cdot \cdot , \beta_1]; [\cdot \cdot , \beta_2]; [\cdot \cdot , \beta_3]; [\cdot \cdot , \beta_4]; \quad (2.10)$$

Burada ele alınan pikselin sağ ve soli üst ve alt, sağ üst ve sol alt, sol üst ve sağ alt pikselleri komşu olarak seçilmiştir.

Üçlüler için;

$$[\cdot \cdot \cdot , \alpha_1]; [\cdot \cdot \cdot , \alpha_2]; [\cdot \cdot \cdot , \alpha_3]; [\cdot \cdot \cdot , \alpha_4]; \quad (2.11)$$

Dörtlü için;

$$[\cdot \cdot \cdot \cdot , \gamma_1]; \quad (2.12)$$

Bunlara göre klik potansiyelleri:

$$V_c(x) = \begin{cases} -\xi & , c \text{ içersindeki tüm } x_{ij} \text{ 'ler esitse} \\ \xi & , \text{diger durumlarda} \end{cases} \quad (2.13)$$

ξ , c klik tipi için belirtilmiş bir parametredir. Tek pikseli kliklerde, klik potansiyeli aşağıdaki şekilde tanımlanır.

$$V_c(x) = \{ \alpha_k ; x_{ij} = q_k \} \quad (2.14)$$

α_k parametresi piksellerin yüzdelerini kontrol eden, diğerleri ise kümeleşme yönünü ve büyüklükleri kontrol eden parametrelerdir.

Sürekli Rastlantı Alanlar : Bir rastlantı alanının olasılık yoğunluk işlevi aşağıdaki gibi ifade edilebiliyorsa, bu bir Sürekli Gibbs Rastlantı Alanıdır.

$$F_x(x) = ke^{-U(x)/Z}, \quad \forall x \in \Omega \quad (2.15)$$

Sürekli rastlantı alanlarında, Gauss rastlantı değişkeni en uygun rastlantı değişkenidir ve bu tür rastlantı alanları görüntü modellemede Gauss Markov Rastlantı Alanları olarak da bilinir.

Öz-Model (Auto-Model) : M noktadan oluşan ve komşuluk ilişkileri belirli bir alanı stokastik bir süreç olarak ele almak mümkündür, bu Hammersley ve Clifford teoremi olarak bilinir. Bu stokastik süreç de bir Markov Alanı olacaktır [5], Hammersley ve Clifford teoreminin tanıtında, a) Kafes üzerindeki her bir noktanın sonlu bir renk değerine sahip olduğu b) pozitiflik özelliği gözönüne alınarak kafes üzerindeki bütün noktaların değerinin 'sıfır' olduğu bir gerçeklemenin (görüntünün) bulunduğu kabul edilmektedir. $P(\Omega) > 0$, Ω bütün noktaları sıfır değerli olan rastlantı vektörünü göstermektedir. Bu iki düşünceden yola çıkarak,

$$Q(X) = \ln \{P(X) / P(0)\} \quad \forall x \in \Omega \quad (2.16)$$

şeklinde bir $Q(X)$ tanımlanabilir. $Q(X)$ aşağıdaki gibi açık bir şekilde yazılabilir. Tanımlama $Q(X)$ ' in açık şekilde yazılımını görmek için Besag, [5] 'a bakılabilir,

$$Q(X) = \sum_{1 \leq i \leq M} x_i F_i(x_i) + \sum_{1 \leq i, j \leq M} x_i x_j F_{i,j}(x_i, x_j) + \sum_{1 \leq i, j, k \leq M} x_i x_j x_k F_{i,j,k}(x_i, x_j, x_k) + \dots + x_1 x_2 \dots x_M F_{1,2,\dots,M}(x_1, x_2, \dots, x_M) \quad (2.17)$$

Bu teorem ışığında (2.17)'de ki F işlevindeki karmaşıklığı basite indirmek için ve Besag'in öne sürdüğü 'öz-Model' lere geçmek için iki varsayımda bulunulacaktır.

Varsayım 1 : İki'den fazla argümana sahip olan F işlevleri yok olur. (Birli ve ikili klikler dışındaki diğer klik tiplerinin enerjileri sıfır olur).

Varsayım 2 : Kafes üzerindeki her bir noktanın koşullu olasılık dağılımı üsteldir.

Bu varsayımlar ışığında GRA ve MRA öz-model olarak tanımlanır ve Q(X) işlevi,

$$Q(X) = \sum_{1 \leq i \leq M} x_i F_i(x_i) + \sum_{1 \leq i, j \leq M} \beta_{i,j} x_j \quad (2.18)$$

olur. Bu durumda, (2.16)'da verilen eşitlik,

$$P(x_i | \dots) / P(0 | \dots) = e^{(x_i \{F_i(x_i) + \sum_{j=1}^M \beta_{i,j} x_j\})} \quad (2.19)$$

şeklinde yeniden yazılabilir. $\beta_{i,j}$ modele ait parametreleri göstermektedir ve

$$\beta_{i,j} = \begin{cases} \beta_{i,j} = \beta_{j,i} , & i = j \\ \beta_{i,j} & , i \neq j \end{cases}$$

2.1.2. GIBBS VE MARKOV RASTLANTI ALAN MODELLERİ

Gibbs Rastlantı Alanlarının potansiyel işlevleri ile tamamen karakterize edilebildiğini gördük . Sadece tek nokta ve nokta çiftlerinden oluşan kliklerle enerji işlevini tanımlamak olasıydı. Öz-model özelliğini kullanarak enerji işlevini yazarsak,

$$U(x) = \sum_{t=1}^M F(x_t) + \sum_{t=1}^M \sum_{r=1}^c H(x_t, x_{t+r}) \quad (2.20)$$

$H(a,b) = H(b,a)$, c değeri komşuluk derecesine bağlı bir değerdir, örneğin, birinci, ikinci, üçüncü, dördüncü ve beşinci dereceden komşulara göre, sırasıyla $c=2, 4, 6, 10, 12$ 'dir (Şekil 2.2). F işlevi tek noktardan, H işlevi ise nokta çiftlerinden oluşan kliklerin potansiyel işlevleridir.

Enerji işlevi $U(x)$ ile tanımlanmış bir GRA (2.15) aşağıdaki yerel koşullu olasılık değerine sahiptir.

$$P(x_t | R_t) = \frac{e^{(-F(x_t) - \sum_{r=1}^c (H(x_t, x_{t+r}) + H(x_t, x_{t-r})))}}{\sum_{s \in \mathcal{A}} e^{(-F(x_s) - \sum_{r=1}^c (H(x_s, x_{t+r}) + H(x_s, x_{t-r})))}} \quad (2.21)$$

(2.20) ve (2.21) deki eşitliklerde bulunan F ve H işlevleri değiştirilerek çeşitli GRA ve MRA modelleri tanımlamak olasıdır.

GRA ve MRA'nın modellere ayrılmasının kuşkusuz çeşitli avantajları vardır. Bunları kısaca şöyle açıklayabiliriz.

i) GRA ve MRA'nın bir modeline ait örnekleme algoritmaları bir diğer GRA ve MRA örnekleme algoritmalarına uyarlanabilir.

ii) GRA ve MRA'nın bir modeli için kullanılan parametre kestirim algoritmaları bir diğer GRA ve MRA modeline uyarlanabilir.

iii) Görünüşte doğal dokulara benzer yapay dokular GRA ve MRA'nın bu modelleri kullanılarak üretilebilir.

iv) Örnekleme ve parametre kestirim yazılımları, doku sınıflamada, görüntü onarımında ve görüntü bölütlemeye doğrudan veya kolayca uyarlama yapılarak kullanılabilir.

Bu modeller ayrıntılı olarak incelenmeyecektir. Fakat bunlar şöyle sıralanabilir;

- i) Derin & Elliott Modeli
- ii) 'Auto-Binomial' Model
- iii) 'Auto-Poisson' Model
- iv) 'Auto-Normal' Model

2.1.2.1. Gibbs Dağılımının Oluşturulması

Gözlenmiş $N_1 \times N_2$ boyutlu bir $y = \{y_{ij}\}$ görüntüsü tanımlayalım. Bu y matrisi Y rastgele Alan kümesinden türetilmiş olsun. Amaç Y Rastgele Alan'ını belirlemek, dolayısıyla gürültülü görüntüyü karakterize etmektir. Y rastgele Alan dağılımını $X = \{X_{ij}\}$, rastgele alanına indiriyoruz ve X rastgele alanı X_{ij} değerlerini her $(i, j) \in L$ için $Q = \{1, 2, \dots, M\}$ kümesinden almaktadır.

$X_{ij}(\omega) = x_{ij} = k$ ise x rastgele alanına bağlı olan (i, j) pikseli k bölge tipine ait demektir. Böylece $x = X(\omega)$ tanımı ile L görüntü kümesi M bölgeye ayrıştırılmış (bölütlenmiş) olur. Her bölge tipi tüm görüntü içerisinde birden fazla noktada görünür olabilir. Örnek olarak bir görüntü içerisinde farklı yapıdaki su birikintileri tek bir bölge tipi ile karakterize edilebilir. Amaç çok sayıda farklı bölge içeren bir görüntüyü daha az, fakat doğru bölgeler ile temsil edebilmektir. Örneğin 256 bölge (seviyeli) bir görüntüyü 8 bölge ile temsil edebilmek.

X alt Rastgele Alanını, Gibbs Rastgele Alanı ile modelleyelim. Bu bir bölge oluşturma işlemidir. Yani Gibbs Dağılımı pikselleri belirli özelliklerine göre

kümeleştirerek belli bir bölgeye atacaktır. Model düşüncesi şu şekilde açıklanabilir; görüntü içerisindeki bir piksel herhangi bir bölgeye aitse, o pikselin komşuluğundaki pikseller de büyük bir olasılıkla aynı bölge içinde olacaktır.

2.1.2.1.1. Bölge Modeli

Görüntü Gauss gürültüsü ile bozulmuş olsun, dolayısıyla:

$$Y(i,j) = F(X_{ij}) + W_{ij} \quad , \quad (i,j) \in L \quad (2.22)$$

F(.) gri seviyeye karşı gelen değer

$$F(X_{ij}) = q_m \quad , \quad \text{eğer } X_{ij} = m \text{ ise} \quad (2.23)$$

{ W_{ij} } sıfır ortalamalı ve σ^2 varyanslı gauss gürültüsüdür ($N(0, \sigma^2)$). Ele alınan bu modelde bölütleme için σ^2 ve bölge şiddetleri q_m değerlerine ihtiyacı vardır.

Gelecek bölümde ele alınacak bölütleme probleminin daha iyi anlaşılması, konuya ait tanımlama ve gelişmelerin anlatılmasının faydalı olacağı düşünüldüğü için bundan sonraki kısımlarda bu başlıkla ilgili anlatım ve bir örnek uygulama anlatılacaktır.

2.1.2.1.2. Bölütleme problemi

Bölütleme probleminin temeli verilen bir gürültülü Y görüntüsünden onun alt kümesi olan bir X kümesini elde etmektir. Kısaca $x=X(y)$ değerini bulmaktır. Problemi istatistiksel olarak ortaya koyunca çözüm için maksimum öncelikli tahmin (MAP : Maximum a posteriori Estimation) kriterini kullanabiliriz. Amaç $P(X=x / Y=y)$ koşullu olasılığını maksimum yapacak x değerini belirli bir kurala göre belirleyecek algoritmayı oluşturmaktır. Dolayısıyla MAP kriterini biraz daha detaylı inceleyelim.

MAP Bölütleme Algoritması

MAP bölütleme algoritması, daha önce de belirtildiği gibi $P(X=x / Y=y)$ koşullu olasılığını maksimum yapacak x değerini bulmaya yönelik bir algoritmadır. Bayes kuralını kullanarak

$$P(X = x / Y = y) = \frac{P(Y = y / X = x)P(X = x)}{P(Y = y)} \quad (2.24)$$

y , en büyüğünü bulma işlemi etkilemediğinden (2.24) eşitliğinin sağ tarafının en büyük olması yeterlidir, yani $P\{X = x, Y = y\}$ ortak dağılımının en büyük olması gerekmektedir. Ortak dağılımın, logaritmasını alırsak;

$$\ln P(X=x/Y=y) = \ln P(X=x) + \ln P(Y=y/X=x) \quad (2.25)$$

x alt küme değerini yani doğru bölgeyi belirlemenin en zor tarafı (2.25) denklemini en büyük yapan değeri bulmak için işlemin $M^{N_1 \times N_2}$ defa tekrarlanmasıdır. Çünkü $N_1 \times N_2$ boyutlu görüntüdeki $N_1 \times N_2$ pikselin herbirisi en büyüğü bulma işleminden sonra bölge sayısı olan M adet değerden birisini alacaktır. Aşağıda örnek olması amacıyla kısaca beyaz gürültü eklenmiş bir görüntü bölütleme algoritması anlatılacaktır.

2.1.2.1.3. Beyaz Gürültü Eklenmiş Bir Görüntü İçin MAP Bölütleme Algoritması

Varsayalım ki, herbir M bölgesi $\{q_m\}_{m=1}^M$ farklı q_m değerlerinden birisi ile gösterilsin. Başlangıçta K seviyeli olan gürültülü görüntümüz bölütleme işlemi sonucunda herbir piksel, değeri $\{q_m\}_{m=1}^M$ değer kümesinden birisi olan M -seviyeli hale gelecektir. Algoritmanın önemli safhalarından birisi de en uygun q_m değerlerini belirleyebilmektir, bunun için iki yöntem vardır.

1. K seviyeli görüntüyü doğrusal kuantalama ile M seviyeli hale getirmek ve q değerlerini belirlemek.

2. K seviyeli görüntüyü doğrusal olmayan kuantalama ile M seviyeli hale getirmek ve q_m değerlerini belirlemek.

Bu tezde yazılan algoritmada doğrusal olmayan kuantalama kullanılmıştır ve q_m değerleri histogram tekniği ile belirlenmiştir. Ayrıca, görüntü beyaz Gauss gürültüsü ile bozulmuş ve X rastgele Alanı ikinci dereceden Gibbs Dağılımı ile modellenmiş olsun. Daha önce belirtildiği gibi algoritmanın amacı (2.25) denklemini en büyük yapan x değerini elde etmektir. Onun için (2.25) denklemini biraz açılırsa:

Y=y gözlemlendiğine Maksimum Olasılık Teorisine göre:

$$\ln P(X=x_m) + \ln P(Y=y/X=x_m) \geq \ln P(X=x_i) + \ln P(Y=y/X=x_i) \quad (2.26)$$

ise $\forall i \neq m$ için $X(y) = X_m = q_m$ 'dir. Çünkü x değerlerini $\{q_m\}_{m=1}^M$ kümesinden almaktadır.

Ayrıca, $y=n+x$ olduğundan dolayı (y: gözlemlenen değerler, n: gauss gürültüsü, x: kaynak değerler)

$$P(Y=y/X=x_m) = P_n(y-x/X=x_m) = P(y-x_m) \quad (2.27)$$

(x ve y istatistiksel bağımsız ise) Modelimizde gauss gürültüsü kullandığı için;

$$P_n(\alpha) = \frac{1}{(2\pi\sigma^2)^{\frac{N_1N_2}{2}}} e^{-\left(\frac{1}{2\sigma^2} \sum_{i=1}^{N_1N_2} \alpha^2\right)} \quad (2.28)$$

$\alpha=y-x$ eşitliğini (2.28) denkleminde yerine koyulursa:

$$P_n(y-x) = \frac{1}{(2\pi\sigma^2)^{\frac{N_1N_2}{2}}} e^{-\left(\frac{1}{2\sigma^2} \sum_{i=1}^{N_1N_2} (y_i-x)^2\right)} \quad (2.29)$$

(2.29) denkleminin logaritması alınırsa,

$$\ln P_n(y-x) = -\frac{N_1N_2}{2} \ln(2\pi\sigma^2) - \left(\frac{1}{2\sigma^2} \sum_{i=1}^{N_1N_2} (y_i-x)^2\right) \quad (2.30)$$

elde ederiz. (2.25) denkleminin birinci bileşeni de açılırsa,

$$P(X=x) = \frac{1}{Z} e^{\sum_{c \in C} V_c(x)} \quad (2.31)$$

Logaritması alınırsa,

$$\ln P(X=x) = -\ln Z - \sum_{c \in C} V_c(x) \quad (2.32)$$

(2.30) ve (2.32) denklemlerini (2.24) denkleminde yerine koyulur ve görüntü piksel piksel taranacağı için denklem piksel bazlı hale getirilirse,

$$\ln P(X = x, Y = y) = l_j = -\ln Z - \sum_{c \in C} V_c(x) - \frac{N_1 N_2}{2} \ln(2\pi\sigma^2) - \left(\frac{1}{2\sigma^2} \sum_{m=1}^M \sum_{i=1}^{N_1} (y_{ij} - q_m)^2 \right) \quad (2.33)$$

Algoritmada herbir $(i, j) \in L$ pikseli için (2.33) eşitliği hesaplanır ve (2.33) eşitliğini en büyük yapan q_m değeri bulunur ve y_{ij} gözlemlenen piksel değeri q_m kuantalanmış değere atanır.

(2.33) eşitliğindeki 1. ve 3. terimler sabit olduğundan dolayı en büyüğü bulma işlemini etkilemeyeceklerinden ihmal edilebilirler, dolayısıyla (2.33) eşitliğinin son hali:

$$l_j = -\sum_{c \in C} V_c(x) - \left(\frac{1}{2\sigma^2} \sum_{m=1}^M \sum_{i=1}^{N_1} (y_{ij} - q_m)^2 \right), \quad (2.34)$$

Bilindiği gibi bir algoritmanın en önemli parametrelerinden birisi de hesaplama zamanıdır ve optimize edilmesi gerekmektedir. MAP Bölütleme algoritmasında herbir piksel için M^{N_1} adım gerekmektedir, çünkü $N_1 \times N_2$ boyutlu görüntüde herbir sütun için M^{N_1} farklı uygun bölütleme olanağı vardır. Bu da demektir ki algoritma her N_2 adımda M^{N_1} hesaplama yapacaktır.

2.2. MARKOV RASTGELE ALANLARI İLE GÖRÜNTÜ İŞLEME

Önceki bölümde MRA ve GRA modelleme ile ilgili bazı temel tanımlar ve bilgiler verilmişti. Bu bölümde ise tezde kullanılan sentetik görüntü datalarının MRA modellenmesi hakkında bilgi verilecektir.

Bölüm 2.2.1’de Gibbs dağılım parametrelerinin nasıl elde edildiği anlatılmış, bölüm 2.2.2’de ise biyomedikal sentetik dataların MRA modellenmesi üzerinde durulmuştur.

2.2.1. Gibbs Dağılım Parametrelerinin Elde Edilmesi

Burada amacımız MRA ile modellenecek her bir görüntü için Gibbs dağılımı parametrelerini kestirmektir. En çok kullanılan parametre kestirim yöntemi Besag [5] tarafından ortaya atılan “kodlama yöntemi” dir. Kodlama yöntemi en basit anlamda alanın geriye kalan elemanlarıyla koşullu olan rastgele değişken alt kümesinin birleşik dağılımını en büyük yapan parametreleri kestirmeye yönelik bir maksimum olabilirlik kestirim yöntemidir.

Bu yöntem doğrusal olmayan denklemler kümesinin çözümünü gerektirir. Bu da bu yöntemi kullanışsız ve onun kullanımını çok zor hale sokar. Kodlama yönteminin kullanılması durumunda karşılaşılan zorluklar gözönünde bulundurulduğunda Derin-Elliot [17]’un ikinci derece komşuluk sistemi η^2 için geliştirdiği yöntemi kullanmak daha kullanışlı olacaktır.

X_i ’yi GRA’da tanımlı ayrık uzay aralığı $Q = \{q_m\}_{m=1}^M$ olan bir sınıf olarak düşünelim. Bu rastgele alandan X_i ’i gerçekleştirme işlemi dağılım parametrelerini kestirmede kullanılması için uygundur. Boyutu (i,j) ve komşuluğu η_{ij} olan bir yer düşünelim. Rotasyon uyumu için X_{ij} ’yi s ve t ’yi de X_{ij} ’nin komşuluk vektörü değerleri olarak gösterelim, o zaman

$$t' = [u_1, u_2, u_3, u_4, v_1, v_2, v_3, v_4]^T, \quad (2.35)$$

Burada u_i ve v_i 'lerin konumları s 'in etrafında olacak biçimde şekil 2.3'de gösterilmiştir.

V_1	U_2	V_2
U_1	S	U_3
V_4	U_4	V_3

Şekil 2.3. S ve ikinci dereceden komşuları

Gösterge fonksiyonu $I(z)$ 'yi aşağıdaki gibi tanımlanabilir,

$$I(z_1, z_2, \dots, z_k) = \begin{cases} -1 & , \quad z_1 \approx z_2 \\ 1 & , \quad \text{diger} \end{cases} \quad (2.36)$$

$$z_k \approx z_{k+1} , \text{ eger } |z_k - z_{k+1}| \leq \varepsilon \quad (2.37)$$

Burada ε pozitif ve çok küçük bir değerdir. Bir diğer gösterge fonksiyonu olan $J(m)$;

$$J_m(s) = \begin{cases} 1 & , \quad s \approx q'_m \\ 0 & , \quad \text{diger} \end{cases} \quad (2.38)$$

$$s \approx q'_m , \text{ eger } |s - q'_m| \leq \varepsilon \quad \text{şeklinde tanımlanır.}$$

Şimdi bu nicelikler ışığında GD'nin potansiyel fonksiyonu açıklanabilir. s 'in yerini (i,j) içeren bütün kliklerin potansiyel fonksiyonlarının toplamı $V(s,t',\theta)$ olsun. O zaman,

$$V(s, t', \theta) \equiv \sum_{c: q_m \in C} V_C(x) \quad (2.39)$$

Burada θ parametre vektörüdür ve aşağıdaki gibi tanımlanır;

$$\theta = [\alpha_1, \alpha_2, \dots, \alpha_M, \beta_1, \beta_2, \beta_3, \beta_4, \gamma_1, \gamma_2, \gamma_3, \gamma_4, \xi_1]^T, \quad (2.40)$$

α parametresi piksellerin yüzdelerini kontrol eden, diğerleri ise kümeleşme yönünü ve büyüklükleri kontrol eden parametrelerdir. Burada $\{\alpha_1, \alpha_2, \dots, \alpha_M\}$ parametre kümesi s pikselinin genlik değerinin benzerliği hakkında bilgi verir ve q_m ' düzeyleme seviyesi ile optimize edilir. $\{\beta_1, \beta_2, \beta_3, \beta_4\}$ parametre kümesi s' in ikili komşuları arasındaki ilişkisi hakkında, $\{\gamma_1, \gamma_2, \gamma_3, \gamma_4\}$ parametre kümesi s' in üçlü komşuları arasındaki ilişkisi hakkında, ξ_1 parametresi ise s' in dördü komşuları arasındaki ilişkisi hakkında bilgi içerir. Bu parametreler aşağıdaki gibi gösterilebilir;

$$\begin{aligned} & \left[\begin{array}{cc} u_1 & u_3 \\ & \beta_1 \end{array} \right], \left[\begin{array}{cc} u_2 & \\ u_4 & \beta_2 \end{array} \right], \left[\begin{array}{cc} & v_2 \\ v_3 & \beta_3 \end{array} \right], \left[\begin{array}{cc} v_1 & \\ & v_4 \beta_4 \end{array} \right], \\ & \left[\begin{array}{cc} v_1 & v_2 \\ v_3 & \gamma_1 \end{array} \right], \left[\begin{array}{cc} v_1 & \\ v_3 & v_4 \gamma_2 \end{array} \right], \left[\begin{array}{cc} v_1 & v_2 \\ & v_4 \gamma_3 \end{array} \right], \left[\begin{array}{cc} & v_2 \\ v_3 & v_4 \gamma_4 \end{array} \right], \quad \left[\begin{array}{cc} v_1 & v_2 \\ v_3 & v_4 \xi_1 \end{array} \right]. \quad (2.41) \end{aligned}$$

GD'nin bu sınıfları için klik potansiyellerini kullanarak $V(s, t', \theta)$ aşağıdaki gibi tekrar yazılabilir;

$$V(s, t', \theta) \equiv \phi^T(s, t')\theta \quad (2.42)$$

Burada,

$$\begin{aligned}
\phi(s, t') = [& J_1(s), J_2(s), \dots, J_M(s), (I(s, u_1) + I(s, u_3)), (I(s, u_2) + I(s, u_4)), \\
& (I(s, v_2) + I(s, v_4)), (I(s, v_1) + I(s, v_3)), (I(s, u_2, v_2) + I(s, u_4, u_3) + I(s, u_1, v_4)), \\
& (I(s, u_4, v_3) + I(s, u_2, u_3) + I(s, u_1, v_1)), (I(s, u_2, v_1) + I(s, u_1, u_4) + I(s, u_3, v_3)), \\
& (I(s, u_1, u_2) + I(s, u_4, v_4) + I(s, u_3, v_2)), (I(s, u_1, v_1, u_2) + I(s, u_2, v_2, u_3) + \\
& I(s, u_3, v_3, u_4) + I(s, u_4, v_4, u_1))]^T \quad (2.43)
\end{aligned}$$

(i,j) merkezli 3x3 boyutunda rastgele değişkenin birlesik dağılımına $P(s, t')$ ve sadece η_{ij} 'de ki rastgele değişkenin birleşik dağılımına da $P(t')$ diyelim. O zaman bu koşullu olasılık, Bayes' kuralına göre şu şekilde yazılabilir,

$$\frac{P(s, t')}{P(t')} = P(s|t') = \frac{e^{-V(s, t', \theta)}}{W(t', \theta)} \quad (2.44)$$

Burada

$$W(t', \theta) \equiv \sum_{s \in Q} e^{-V(s, t', \theta)} \quad (2.45)$$

Tekrar düzenlenirse,

$$\frac{e^{-V(s, t', \theta)}}{P(s, t')} = \frac{W(t', \theta)}{P(t')} \quad (2.46)$$

elde edilir. (2.46) eşitliğinin sol tarafına göre görüntü uzayındaki iki farklı ($s=j$ ve $s=k$) değer için,

$$e^{-V(j, t', \theta) + V(k, t', \theta)} = \frac{P(j, t')}{P(k, t')} \quad (2.47)$$

(2.47) eşitliğinin doğal logaritması alınıp (2.42) denkleminde $V(s,t',\theta)$ 'nin yerine konulursa,

$$(\phi(k,t') - \phi(j,t'))^T \theta = \ln\left(\frac{P(j,t')}{P(k,t')}\right) \quad (2.48)$$

Elde edilir. (2.48) 'de ki $((\phi(k,t') - \phi(j,t'))$ vektörü, θ bilinmeyen parametre vektörü kestirilirken, j,k,t' değerleri için kolayca bulunabilir. $P(k,t')$ ve $P(j,t')$ olasılıkları ise histogram tekniği kullanılarak bulunur. Bu histogram tekniği şu şekilde açıklanabilir. Sahip olunan görüntü uzayından bir nokta alınır (k). Alınan bu k noktasının piksel değerinin bütün uzaydaki toplam sayısının , bu uzaydaki bütün piksel sayısına oranı $P(k,t')$ olasılığını verir. $P(j,t')$ olasılık değeri yine aynı şekilde bulunur.

2.2.2. MARKOV RASTGELE ALAN MODELLENMESİ

2.1.2'inci bölümde ayrıntılı olarak nasıl çıkarıldıkları anlatılan (2.34) eşitliği aşağıdaki şekilde tekrar yazabilir;

$$l_j = -\phi^T(s,t')\theta - \left(\frac{1}{2\sigma^2} \sum_{m=1}^M \sum_{i=1}^{N_i} (y_{ij} - q_m)^2\right) \quad (2.49)$$

Burada $\phi^T(s,t') * \theta = Vc(x)$ dir. $Vc(x)$ kullanılan görüntülerde ki herbir pikselin GD parametrelerini verir.

y_{ij} : Orjinal görüntünün bolütlenmiş ve gürültü eklenmiş şeklidir.

q_m : 8 seviyeli düzeyleme seviyesidir.

σ_m : Orjinal görüntüye eklenen beyaz gauss gürültüsünün gücü (varyans) dür

(2.49) eşitliğinin sağ tarafında ki,

$$\left(\frac{1}{2\sigma^2} \sum_{m=1}^M \sum_{i=1}^{N_i} (y_{ij} - q_m)^2 \right) \quad (2.50)$$

(2.50) eşitliği öklid uzaklığı olarak bilinir ve bu eşitliği en küçük (minimum) yapan q_m düzeyleme seviyelerini verir.

Bir önceki bölümde teorik altyapısı anlatılan GRA ve MRA'ların bu bölümde özel bir uygulaması yapıldı. Önce herbir görüntünün Gibbs dağılımlarının nasıl kestirildiği gösterildi ardından biyomedikal görüntülerin MRA modellemesi anlatıldı.

MRA ve GRA ile modellenmiş biyomedikal görüntülerin benzetim sonuçları bulgular kısmında gösterilmiştir. Gürültü eklenen görüntüleri MRA ile modelleyip filtreleme işlemi yapıldığında iyi sonuçlar elde edilmektedir. Yalnız hesap yükünün fazla olması nedeniyle hesap süresinin çok fazla olması MRA'nın dezavantajlarından birini teşkil etmektedir.

GD parametreleri elde edilirken sadece ikinci komşuluk parametreleri bulunarak modelleme yapılmıştır. Birinci, üçüncü ve dördüncü komşuluk parametreleri de katılarak hesaplamalar yapıldığı takdirde daha iyi sonuç elde edileceği düşünülmektedir.

2.3. YAPAY SİNİR AĞLARI VE HÜCRESEL YAPAY SİNİR AĞLARI

Günümüzde sayısal bilgisayarlar yardımıyla bir programı çözmeye yönelik olarak yapılan tüm hesaplamalar belli bir sıraya göre gerçekleştirilmektedirler. İnsan beyninin biyolojik yapısından esinlenerek ortaya konulmuş bir hesaplama yöntemi olan yapay sinir ağları ise basit bir görevi gerçekleştiren bir yapının (nöron) kendi aralarında paralel ve çok sayıda bağlantı oluşturmaları sonucu oluşan bir ağ kümesidir [19]. Bu tür bir yapının sayısal bilgisayarlara göre bazı avantajları vardır. Bunlardan en önemlisi böyle bir yapıda belli bir sıra izlenmediği için yapının herhangi bir noktasında meydana gelebilecek bir bağlantı kopukluğunun, yapının tüm çalışmasını ve gidiş yönünü çok fazla etkilemeyecek olmasıdır. Bunun da en önemli sebebi yapay sinir ağlarında bilginin nöronlar arasındaki bağlantı ağlarında saklı olmasıdır. Buna karşın sayısal bilgisayarlarla yapılan hesaplamalar belli bir sırayı izlemek zorunda kaldığından yazılan kodun herhangi bir noktasında oluşabilecek hata programının gidiş yönünü tamamen değiştirebilecektir. Bunun yanısıra yapay sinir ağları doğrusal olmayan yapıları nedeniyle gerçek yaşam problemleriyle de oldukça başdaşmakta ve gerçek dünya problemlerine doğrusal teknikler kullanan çözümlerden çok daha doğru çözümler getirmektedirler. Günümüz bilgisayarları özellikle hız ve doğruluk bakımından insanlardan yüzlerce kat başarılı olmalarına rağmen insan beyninin gerçekleştirdiği işlevlere henüz sahip değildirler. İnsan beyninin tanıma, öğrenme hesaplama, hatırlama gibi bir çok işlevleri vardır. Bilgisayarlar bu derece hızlı olmalarına rağmen halen insanların veya insan dışındaki daha basit yapıdaki canlıların gerçekleştirdikleri işleri veya çözdükleri cisim tanıma, konuşma gibi (değişik ışık ve renkler altında) problemlerin üstesinden tam olarak gelememektedirler.

İki boyutlu oluşturacak şekilde sıralanmış hücrelerden oluşan hücresel yapay sinir ağlarında her hücre bilinen yapay sinir ağlarının aksine yakın komşuluğundaki hücrelerle bağlantı halindedirler. Gerek bu durum ve gerekse hücreler arasındaki bağlantı ağırlık katsayılarının (genelde) çalışılan düzlemde değişmemesi durumu, hücresel yapay sinir ağlarını ortaya atıldıkları 1988 yılından itibaren özellikle görüntü işleme konularında (kenar belirleme, gürültü temizleme, boşluk doldurma vb.) oldukça geniş kullanım alanlarına sahip olmasını sağlamıştır. Böylece klasik yapay sinir ağlarına kıyasla bir görüntüden istenilen amaca yönelik başka bir görüntünün elde edilmesi işlemi daha az katsayı kullanılarak gerçekleştirilebilmektedir.

2.3.1. YAPAY SİNİR AĞLARI

Mevcut bilgisayarlarla ve algoritmalarla çözülemeyen ya da iyi sonuçlar alınamayan, fakat insan beyninin kolayca yapabildiği karmaşık problemlere çözümler üretmek için son yıllarda yapılan araştırmalar sonucu, yeni bir bilgi işleme yöntemi olarak Yapay Sinir Ağları (YSA) doğmuştur.

YSA, biyolojik sinir sisteminin bazı fonksiyonlarını modelleyen ve onun bazı yeteneklerini yakalamak isteyen basit işlem elemanlarının yoğun bir paralel dizisidir. Başka bir deyimle, birbirlerine yoğun bir şekilde paralel olarak bağlanmış basit işlem elemanlarından oluşmuş ve gerçek dünyadaki nesnelere biyolojik sinir sisteminin yaptığı gibi aynı şekilde etkileşmek üzere hiyerarşik olarak düzenlenmiş ağlardır.

Nöronlar beyin temeli fonksiyonel birimleridir. Bir insan beyni yaklaşık olarak 10^{11} nörona meydana gelmiştir. Bu nöronlarda vücudun gerekli hareket ve duyu organlarına bağlanmasını sağlayan yine yaklaşık 10^8 bağlantı elemanı vardır. Biyolojik açıdan ele aldığımızda bir nöronun temel olarak üç kısımdan meydana geldiğini görürüz. Bunlar; nöronun temel yapısını oluşturan hücre gövdesi, tek ve uzun bir yapıdan oluşan ve hücrenin çıkış birimi olarak adlandırabileceğimiz axon ve kısa kısa çok sayıda iplikçiklerden oluşmuş olan ve giriş birimi olarak adlandırabileceğimiz dendrit. Nöronlar arasındaki bağlantılar ise snaps olarak adlandırılır. Bu biyolojik yapıdan esinlenerek YSA modellenmiş ve uygulamalar gerçekleştirilmiştir.

Yapay sinir ağlarına ilişkin ilk çalışmalar McCulloch ve Pitts tarafından 1943 yılında nöronun tanıtılmasından sonra başlamıştır[19]. Bu nöronlar biyolojik nöronların bir modelleri ve kavramsal olarak bir devrenin belli bir görevi yerine getirecek hesaplama elemanları olarak ortaya konmuşlardır. Biyolojik sinir hücresinin yapısından esinlenerek geliştirdikleri bir yapay sinir hücre modeli ile VE, VEYA gibi mantık işlemlerinin yapılabileceğini gösterdiler. Böylece, biyolojik sinir sistemlerinin incelenmesi ve onlara benzer şekilde çalışan YSA modellerinin geliştirilmesi çok farklı bilim dalından araştırmacıların ortak olarak çalıştığı bir bilim dalı alanı oluşturdu.

Bu iki bilim adamı çalışmalarında tanımladıkları iki durumlu eşik seviyesine sahip nöronlarla istenilen sayısal işlevlerin gerçekleştirilebileceğini göstermişlerdir. Bu da daha sonra bu basit sayısal işlevlerden yararlanılarak daha karmaşık işlevlerin ve hesaplamaların yapılabileceğine işaret etmiştir. 60'lı yılların ortalarından, 80'li yılların başına kadar bir durgunluk dönemi yaşadı. Durgunluğa sebep gösterilebilecek en önemli olgu, YSA'nın bilgi işlemede alternatif olan günümüzün sayısal bilgisayarlarının yarıiletken teknolojisiyle yoğun, büyük çapta, ucuz ve güvenilir gerçekleştirme olanağı bulmasıdır. Seri olarak çalışan hızlı birimlerden oluşmuş sayısal bilgisayarlar, aritmetik işlemlerde yüksek hız, kapasite ve güvenilirlik sağlamışlardır.

Sayısal bilgisayarların görüntü ve ses işaretlerinin işlenmesinde yapısal olarak güçsüz olduğunun görülmesi, buna karşın biyolojik sistemlerin bozulmuş ve tam tanımlı olmayan yüksek veri yoğunluğuna sahip bilgilerin işlenmesinde sayısal bilgisayarlara

göre çok hızlı ve yüksek doğrulukta çalışması 1980'lerde çeşitli bilim dallarından büyük bir araştırma kitlesinin YSA'lara olan ilgisini arttırmıştır.


1976'da Grossberg, Adaptif Rezonans Teoriyi (ART), 1982'de Hopfield, optimizasyon gibi teknik problemleri çözmek için lineer olmayan dinamik Hopfield ağını ve 1984'te de Kohenen eğitici-siz öğrenen bir ağ geliştirmiştir[20].

1986 yılında Rumelhart, günümüzde en çok kullanılan algoritma olan çok katmanlı algılayıcı tipi ağlar için geriye yayılma algoritmasını geliştirmiştir[20]. YSA'nın çok geniş uygulama alanı mevcut olmakla beraber en çok kullanılan alanlar fonksiyon yaklaşırma, görüntü tanıma, görüntü ve ses işleme, sistem tanıma ve kontroldür.

2.3.1.1. Yapay Sinir Ağlarının Tanımı ve Özellikleri

Gelişen teknolojinin yazılım ve donanım geliştirme ortamları üzerinde tasarımcıya sunmuş olduğu olanakların gün geçtikçe çeşitlilik kazanması karmaşık sistemleri ortaya çıkarmış ve bu, gerek çözümü aranan problemlerin matematiksel modellerinin geliştirilmesini gerekse bu problemlere önerilen çözümlerde istenen hassasiyetin ve bozucu çevresel etkenlere karşı duyarsızlık özelliğinin kazanılmasını güçleştirmiştir. Bu anlamda YSA'ların kullanımı ile önerilebilecek çözümlerin istenen özellikleri taşıyor olmaları, bu yaklaşımları birçok alanda tercih edilen yöntemler haline getirmiş ve bu şekilde tanımlanmışlardır. Ayrıca, YSA konusu üzerinde çalışırken, bir ağ yapısının çözebileceği problem uzayının, insan beyninin çözebildiği problem uzayının oldukça kısıtlanmış bir alt kümesi olacağı gözden kaçırılmamalıdır.

Basit bir nöron modeli; n tane ağırlaştırılmış girişin toplanması ve bu toplamdan bir eşik seviyesinin çıkarılması sonucu elde edilen değerin aktivasyon fonksiyonu adı da verilen bir fonksiyondan geçirilmesi temeline dayanır. Görüldüğü gibi nöron modeli, nöronun eşik değeri ve kullanılan doğrusal olmayan aktivasyon fonksiyonu tarafından belirlenmektedir. Sözgelimi çıkışında sadece iki farklı seviyenin olmasının yeterli olacağı durumlarda katı sınırlamalı bir çıkışa sahip olan eşik seviyesinin kullanılması nöronu modellemek için yeterli olabileceken, çoklu çıkışların bulunması durumunda ise nöronu modellemek için sigmoid fonksiyonun kullanılması gerekebilecektir. Bu basit nöron modelinin yanısıra içerisinde zamana bağlı entegrasyon veya daha farklı operatörlerin kullanıldığı ve toplamadan daha karmaşık matematiksel ifadelerin yer aldığı nöron modelleri de kullanılmaktadır. Sözgelimi sonraki bölümler de ayrıntısıyla ele alınacak olan hücresel yapay sinir ağları bu türden karmaşık bir nöron yapısına örnek olarak gösterilebilir.



Şekil 2.4. Tek gizli katmanlı yapay sinir ağı modeli

Tek olarak düşünüldüklerinde oldukça basit bir işleve sahip oldukları görülen nöronlar bir arada kullanıldıklarında oldukça karmaşık işlemleri gerçekleştirebilecek yapıya dönüşebilmektedir. En genel anlamda bir yapay sinir ağı modeli Şekil 2.4' te gösterildiği gibidir. Bu şekilden de görülebileceği gibi her nöronun bir çok giriş işareti ve tek çıkışı vardır. Bu çıkış diğer nöronların girişlerini oluşturur ve sistem böylece paralel bir şekilde yayılır. Buradaki giriş-çıkış sayıları ile gizli katmanlar, gerçekleştirilecek işe göre birden fazla gizli katman seçilebileceği gibi, her gizli katmandaki nöron sayısı da değişiklikler gösterebilir. Bu tür yapılarda geri beslemelerin de işin içine katılmasıyla oldukça karmaşık fonksiyonlar elde edilebilmektedir [21].

Geri beslemeli sistemlerin çalışması sistem içerisinde az sayıda geri besleme bulunması ve transfer fonksiyonlarının doğrusal olması durumunda bile oldukça karmaşıktır. Bu durumda insan beyni ele alınacak olursa; gerek doğrusal olmayan transfer fonksiyonuna sahip olması ve gerekse içinde barındırdığı yaklaşık olarak 10^{15} seviyesindeki geri beslemeli çevrim sayısından dolayı bu sistemin karmaşıklığı daha net bir şekilde ortaya çıkabilir.

Sistemdeki her bir nöron aslında tek başına bir işleme elemanıdır ve çevresindeki komşularından bağımsız olarak kendi üzerine düşen görevi yerine getirir. Ancak, yapay sinir ağı yapısındaki tüm nöronların davranışları birlikte ele alındığında, her bir nöronun çıkışı başka bir nöronun girişini oluşturduğundan sistem içindeki her bir nöronun sistemin davranışını dolaylı olarak etkilediği görülür.

YSA'nın klasik bilgi işleme yöntemlerine göre üstünlükleri şu şekilde sıralanabilir :

i) Paralellik : Sistemin paralelliği ve toplamsal işlevin yapısal olarak dağılımıdır. Diğer bir deyişle birçok nöron eşzamanlı olarak çalışır ve karmaşık bir işlev çok sayıda küçük nöron aktivitesinin bir araya gelmesinden oluşur. Bu da, zaman içerisinde herhangi bir nöronun işlev dışı kalması durumunda ağ başarımının dikkate değer ölçüde etkilenmeyeceği anlamına gelir. Sonuç olarak eşzamanlılıkla hız çok artmaktadır.

ii) Genelleme Yeteneği : Ağ yapısının, eğitim esnasında kullanılan sayısal bilgilerden eşleştirmeyi betimleyen kaba özellikleri çıkarsaması ve böylelikle eğitim sırasında kullanılmayan girdiler için de anlamlı cevaplar üretebilmesidir.

iii) Doğrusal Olmama: Bir başka özellik de ağ fonksiyonunun doğrusal olmayan oluşudur. Yapı üzerinde dağılmış belli tipteki doğrusal olmayan alt birimler özellikle, istenen eşleştirmenin denetim ya da tanılama işlemlerinde olduğu gibi doğrusal olmayan durumda işlevin doğru biçimde yerine getirilebilmesini matematiksel olarak olası kılarlar. Burada, işlevin doğru biçimde gerçekleştirilmesi için yapısal bir esneklik gerekliliği vurgulanmalıdır.

iv) Gerçekleme Kolaylığı : YSA, karışık fonksiyonlar yerine basit işlemleri içerdiği için gerçeklemek kolaydır. Özellikle robotik uygulamaları ile birlikte düşünüldüğünde, günlük yaşamda yaşam kalitesinin artırılmasında ne denli önemli bir rol oynayabilecekleri görülebilir. YSA'da her bir işlem birimi, çözülecek problemin tümüyle ilgilenmek yerine, sadece problemin bir parçası ile ilgilenmektedir. Hücrelerin çok basit işlem yapmalarına rağmen, sağlanan görev paylaşımı sayesinde çok karmaşık ve zor problemler çözülebilmektedir.

v) Hata Toleransı : Geleneksel bir bilgisayarda, herhangi bir işlem elemanını yerinden almak, onu etkisiz bir makinaya dönüştürür. Ancak YSA'da bir eleman meydana gelen hasar, performansta ciddi bir düşüğe yol açmaz.

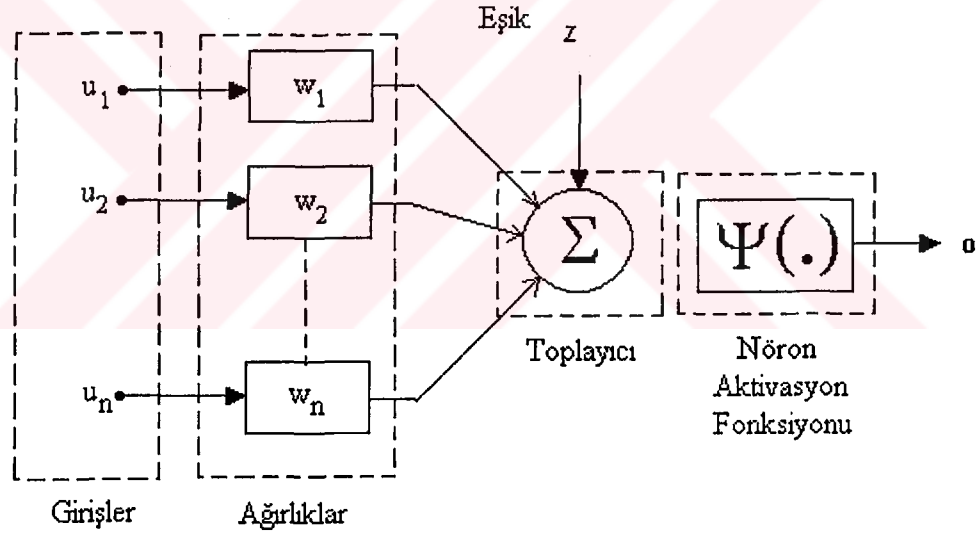
vi) Öğrenebilirlik : Alışlagelmiş veri işleme yöntemlerinin çoğu programlama yolu ile hesaplamaya dayanmaktadır. YSA ise problemleri, verilen örnekler ile çözer. Yani, YSA programlama yerine örneklerle eğitilir.

2.3.1.2. Matematiksel Nöron Modeli

Nöronlar sinir ağlarını oluşturan, tek başına ele alındıklarında çok basit işleve sahip işlemcilerdir. Bir nöron yapısı içerisinde üç ana bölüm bulunur. Bunlar sırasıyla sinapslar, toplayıcı ve aktivasyon fonksiyonudur. Şekil 2.5'te bir nöron modeli gösterilmektedir. Bu şekilden de görülebileceği gibi, nöron girdileri sinaptik bağlantılar üzerindeki ağırlıklar ile çarpılarak bir toplayıcıya uygulanmakta ve elde edilen toplam, nöronun aktivasyon fonksiyonundan geçirilerek çıkışlar hesaplanmaktadır. (2.51) denkleminde ağırlıklı toplamın oluşturulması, (2.52) denkleminde ise nöron çıkışının hesaplanması verilmektedir.

$$\sum_{i=1}^n w_i u_i - Z \quad (2.51)$$

$$o = \Psi(S) \quad (2.52)$$




Şekil.2.5. Nöron Yapısı

Her bir girdideki değişim, nöron çıkışında belli bir değişime neden olmakta ve bu değişimin genliği, girdinin etki derecesini belirleyen bağlantı kazançlarına, toplayıcının eşik değerine ve nöron aktivasyon fonksiyonunun tipine bağlı olmaktadır. Burada w_i ile gösterilen kazançlar ağırlık olarak, Z değeri eşik olarak, Ψ fonksiyonu da nöron aktivasyon fonksiyonu olarak isimlendirilmektedir. Yukarıdaki denklemlerden de görülebileceği üzere eşik değerinin girdilerden bağımsız olmasından dolayı bütün girdilerin sıfır olmaları durumlarda nöron çıkışında $\Psi(0)$ yerine $\Psi(Z)$ değeri gözlenir ki bu da belirtilen şartlar altında nöron çıkışının sıfır olması zorunluluğunu ortadan kaldırır. Eşik değerinin kullanımı, pratikte +1 ya da -1

değerine sahip sabit bir girdinin Z ağırlığına sahip bir bağlantı ile toplayıcıya girdiği şekilde ele alınır.

2.3.1.3. Aktivasyon Fonksiyonları

Nöron davranışını belirleyen önemli etmenlerden biri nöronun aktivasyon fonksiyonudur. Biyolojik nöronlarda S ile gösterilen toplam, belli bir değeri aştığında nöronun kısa süreli bir darbe gönderdiği bilinmektedir. Bu davranışa benzer bir davranışı yapay nöronlarla da elde etmek için kullanılan aktivasyon fonksiyonlarından üçü Şekil 2.6'da gösterilmiş, matematiksel ifadeleri ise (2.53), (2.54) ve (2.55) denklemlerinde verilmiştir.



- a) Sigmoid tipi aktivasyon fonksiyonu
- b) Hiperbolik tanjant tipi aktivasyon fonksiyonu
- c) Sert geçişli aktivasyon fonksiyonu

Şekil 2.6. Aktivasyon Fonksiyonları

Sigmoid tipi aktivasyon fonksiyonu

$$\Psi_1(S) = \frac{1}{1 + e^{-s}} \quad (2.53)$$

Hiperbolik tanjant tipi aktivasyon fonksiyonu

$$\Psi_2(S) = \frac{e^S - e^{-S}}{e^S + e^{-S}} \quad (2.54)$$


Sert geçişli tipte aktivasyon fonksiyonu

$$\Psi_3(S) = \begin{cases} 0, S \leq 0 \\ 1, S > 0 \end{cases} \quad (2.55)$$

Uygulamalarda nöron cevabının, girdilerin sürekli bir fonksiyonu olmasını gerektiren durumlarda (2.53) ya da (2.54) denklemlerinde verilen aktivasyon fonksiyonları kullanılırken, ikili karar mekanizması gerektiren durumlarda (2.55) ile tanımlanan sert geçişli aktivasyon fonksiyonları tercih edilmektedir. Aktivasyon fonksiyonunun parametrik olması, sinaptik ağırlıkların kazandırdığı esnekliğin ötesinde, değişik eşleştirmelerin yapılabilmesini mümkün kılan bir başka esneklik sağlar. Bu amaçla, (2.54) denklemi ile verilen hiperbolik tanjant tipindeki aktivasyon fonksiyonu, (2.56) denkleminde olduğu gibi yeniden düzenlenebilir.

$$\Psi_2(S) = \frac{e^{\lambda S} - e^{-\lambda S}}{e^{\lambda S} + e^{-\lambda S}} = \tanh(\lambda S) \quad (2.56)$$


(2.56) denkleminde λ parametresinin değiştirilmesiyle aktivasyon fonksiyonunun yapısı Şekil 2.7'de de gösterildiği gibi değiştirilebilir. Bu durum özellikle, öğrenme denilen zaman içerisinde parametrelerin güncellenmesi işleminde önemli bir husustur.



Şekil 2.7. Farklı λ değerleri için (2.56) denkleminin tanımladığı aktivasyon fonksiyonunun görünümü

2.3.1.4. Yapay Sinir Ağ Modelleri

Tek olarak düşünüldüklerinde oldukça basit bir işleve sahip oldukları görülen nöronlar bir arada kullanıldıklarında oldukça karmaşık işlemleri gerçekleştirebilecek bir yapıya dönüşebilmektedir. En genel anlamda bir yapay sinir ağ modeli şekil.2.8. de gösterildiği gibidir. Bu şekilden de görülebileceği gibi her nöronun bir çok giriş işareti ve tek çıkışı vardır. Bu çıkış diğer nöronların girişlerini oluşturur ve sistem böylece paralel bir şekilde yayılır. Buradaki giriş-çıkış sayıları ile gizli katmanlar, gerçekleştirilecek işe göre değişik büyüklüklerde seçilebilirler. Her yapıda yapılacak olan işe göre birden fazla gizli katman seçilebileceği gibi, her gizli katmanda ki nöron sayısı da değişiklikler gösterebilir. Bu tür yapılarda geribeslemelerin de işin içine katılmasıyla oldukça karmaşık fonksiyonlar elde edilebilmektedir[21]. Geri beslemeli sitemlerin çalışması sitem içerisinde az sayıda geribesleme bulunması ve transfer fonksiyonlarının doğrusal olması durumunda bile oldukça karmaşıktır. Bu durumda insan beyni ele alınacak olursa; gerek doğrusal olmayan transfer fonksiyonuna sahip olması ve gerekse içinde barındırdığı yaklaşık olarak 10^{15} seviyesindeki geribeslemeli çevrim sayısından dolayı bu sistemin karmaşıklığı daha net bir şekilde ortaya çıkabilir.



Şekil 2.8. Tek katmanlı ileri beslemeli ağ modeli

Bu sistemdeki her bir nöron aslında tek başına bir işleme elemanıdır ve çevresindeki komşularından bağımsız olarak kendi üzerine düşen görevi yerine getirir. Ancak yapay sinir ağ yapısındaki tüm nöronların davranışları birlikte ele alındığında, her nöronun çıkışı başka bir nöronun girişini oluşturduğundan sistem içindeki her bir nöronun sistemin davranışını dolaylı olarak etkilediği görülür.

2.3.1.5. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarında ki öğrenme, sistemden yapılması istenen işe uygun olarak bağlantı ağırlık katsayılarının hesaplanması temeline dayanmaktadır. Öğrenme kuralı ise, istenen amaca yönelik olarak ağırlık katsayılarının bazılarının veya tümünün değiştirilmesine yönelik olan bir denklem takımı olarak ifade edilebilir. Bu kural zamanla herbir nöronun cevabının değişmesine ve dolayısıyla ağı kendisini istenen cevaplara uyarlayabilmesine, bilgiyi kendi içinde istediği gibi düzenleyebilmesine veya kısaca öğrenmesine olanak tanır.

Yapay sinir ağları, programlama yerine örnekler ile eğitilir. Eğitim işlemi öğreticili ve öğreticisiz olmak üzere iki şekilde yapılır[22]. Öğreticili bir eğitimde sisteme hem giriş bilgisi, hem de bu girişe karşın üretilmesi istenen çıkış bilgisi verilir. Böylece her denemeden sonra istenilen çıkış ile gerçek çıkış değerleri arasındaki fark öğrenme kuralına bağlı olarak uyarlanan ağırlık katsayılarına ile en aza indirilmeye çalışılır. Çıkış hatası kabul edilebilir bir seviyeye gelince eğitim işlemine son verilir ve daha sonra eğitimde yer almamış yeni, setler üzerinde elde edilen bu ağırlık katsayılarının veya başka bir deyişle ağı başarımına bakılır.

Öğreticisiz eğitimde ise herhangi bir ulaşılması istenen hedef vektörü ağa verilmez. Sadece girişler sisteme verilir ve sistem bu girişleri alarak kendisini öz-örgütler. Bu tür öğrenme kuralları özellikle sınıflandırma problemleri için kullanılmaktadırlar. Kohonen ve Grossberg tarafından geliştirilmişlerdir [23-24].

2.3.2 HÜCRESEL YAPAY SİNİR AĞLARI

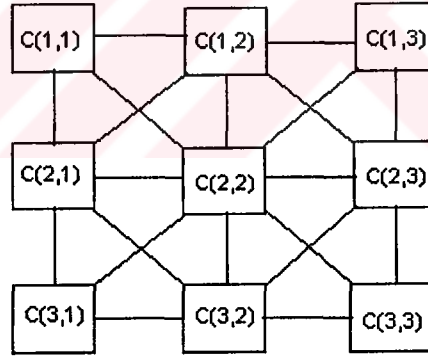
Yapay sinir ağlarının özel bir çeşidi olan Hücresel Yapay Sinir Ağları (Cellular Neural Network - CNN) ilk olarak 1988 yılında L. Chua ve L. Yang tarafından ortaya atılmışlardır [25-26]. Birbirine bağlı ve çoğunlukla iki boyutlu hücrelerden meydana gelmiş olan dinamik yapay sinir ağlarıdır. Bu yapıyı bildiğimiz anlamdaki yapay sinir ağlarından en önemli özelliği, bağlantı ağırlık katsayılarının çalışılan düzlem üzerinde değişmez bir bağlantı ağı oluşturmasıdır. Bu da hücresel yapay sinir ağlarını klasik anlamdaki yapay sinir ağlarına göre oldukça avantajlı bir konuma sokmaktadır. Bilinen anlamdaki yapay sinir ağlarının bazı temel özelliklerini taşımalarının yanı sıra özellikle iki boyutlu yapılarından dolayı görüntü işleme ve görüntü tanıma konularında oldukça fazla uygulama alanları bulmaktadırlar[27-31].

Hücresel yapay sinir ağları, paralel çalışma ve iki boyutlu özelliklerinden dolayı bu alanda karakterlerin bazı ayırt edici özelliklerinin çıkarılmasını sağlayan bir ön işleme elemanı olarak kullanılmalarına neden olmuştur. Burada üzerinde işlem yapılacak

olan görüntüdeki her noktada bir nörona karşılık düşmektedir. Böyle bir yapıda görüntü Hücrel yapay sinir ağına doğrudan verilebileceği gibi, özellikle görüntünün bazı ayırt edici özelliklerinin ortaya çıkarılmasını sağlayan bir ön işlemden geçirildikten sonra da ağa verilebilmektedir. Bunun yanı sıra Hücrel yapay sinir ağının kendisi de bir ayırt edici özellik çıkarıcı olarak kullanılabilir[32-33]. Hücrel yapay sinir ağları görüntü işleminin yanı sıra hareket sezme işlemlerinde de kullanılmaktadır[34-35].

Sözelimi Hücrel yapay sinir ağlarından bu amaçla 60000 civarında karaktere sahip olan ve bunlardan 6000 tanesinin günlük yaşamda kullanıldığı Japon alfabesindeki karakterleri tanımak için yararlanılmıştır. Japon karakterlerindeki bu fazlalık nedeniyle tanıma problemi doğal olarak diğer karakterlerin tanıma problemlerine nazaran çok daha zordur.

İki boyutlu bir dizi oluşturacak şekilde sıralanmış hücrelerden meydana gelmiş olan bu yapılarda, bilinen yapay sinir ağlarının aksine buradaki her hücre yakın komşuluğundaki hücrelerle belli bir komşuluk ilişkisi altında bağlantı halindedir. Şekil 2.9, her bir hücrenin sadece çevresindeki hücrelerle bağlantı halinde olduğu 3x3 boyutunda bir Hücrel yapay sinir ağını göstermektedir [25].




Şekil 2.9. 3x3 boyutunda bir Hücrel Yapay Sinir Ağı gösterimi

Bir Hücrel yapay sinir ağının görüntü işlemedeki temel fonksiyonu herhangi bir giriş görüntüsünü istenilen amaca uygun olarak bir çıkış görüntüsüne dönüştürmesidir. Burada çıkış görüntüsü Hücrel yapay sinir ağları ilk haliyle ele alındığında her piksel değeri -1 ve $+1$ olacak şekilde sınırlandırılır. Ancak buna karşılık giriş görüntüleri uygun gerilim değerleri de sağlandıktan sonra, çoklu gri seviyelerine de sahip olabilirler. Verilen bir giriş görüntüsü ile başlatılan veya sürülen herhangi bir geçici rejim sonrasında, Hücrel yapay sinir ağından geçirilmiş görüntü, gerekli koşullar sağlandığı taktirde her zaman bir kararlı durum sabit noktasına yakınsamaktadır.

Görüntü işlemede hücrel yapay sinir ağlarında genel olarak yapılan işlem, verilen bir giriş görüntüsünün doğrusal olmayan ve dinamik bir işlemle geçirilerek çıkış görüntüsünün oluşturulmasıdır. Yapının dinamik olmasından dolayı istenilen kararlı görüntü durumu elde edilene kadar çıkış görüntüsü her zaman aralığında sürekli değişim göstermektedir. Hücrel yapay sinir ağlarının komşuluk düzenindeki bu yapıları özellikle tüm-devre gerçeklemlerinde büyük kolaylıklar sağlamıştır.

2.3.2.1. Hücre Yapıları

Hücrel yapay sinir ağlarındaki bu yapıda her bir hücre ağırlıklı toplama yapan doğrusal bir giriş birimi, doğrusal dinamik bir ara birim ve n parçalı (genellikle üç parçalı) orijine göre simetrik bir çıkış ara biriminden oluşan dinamik bir devredir. Aşağıdaki devrede gösterilen u girişi, $y(n)$ çıkışı, A,B,I öğrenme algoritmasındaki ağırlık katsayılarını veren parametreler, $f(.)$ ise aktivasyon fonksiyonunu gösterir.



Şekil 2.10. Bir hücrenin dinamik yapısı

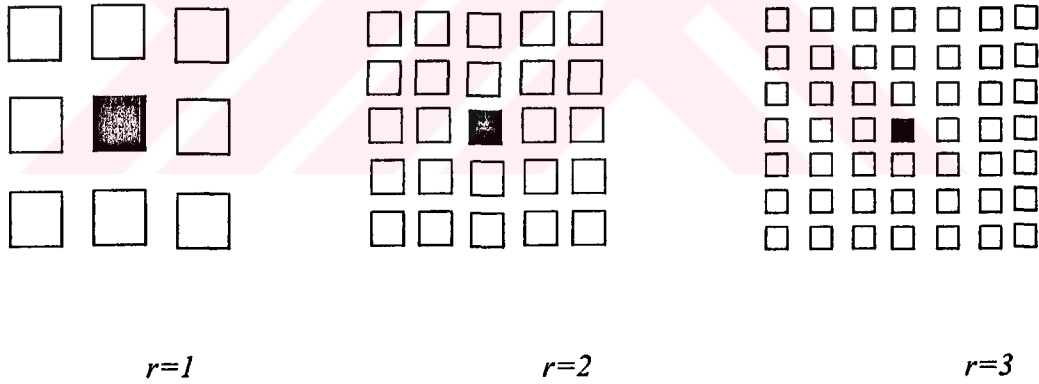
Bu devredeki hücrelerin her biri doğrusal ve doğrusal olmayan dirençler, kapasiteler, akım ve gerilim kontrollü kaynaklar içerirler. Teorik açıdan hücrel yapay sinir ağları çok boyutlu olarak tanımlanabilmelerine rağmen tez boyunca yapılan çalışmalarda özellikle görüntü işleme uygulamaları üzerinde durulduğundan burada ele alınan hücrel yapay sinir ağları iki boyutlu olarak kullanılmıştır. Ancak istenildiği takdirde elde edilen sonuçlar kolaylıkla daha yüksek boyutlu durumlara genelleştirilebilir.

2.3.2.2. Hücresel Yapay Sinir Ağlarında Komşuluk İlişkisi

M satır ve N kolondan bir $M \times N$ 'lik hücresel yapay sinir ağı ele alalım. Böyle bir yapıda i . satır ve j . kolona (i,j) hücresi adını verip $C(i,j)$ olarak ifade edelim. Burada herhangi bir $C(i,j)$ hücresinin r -komşuluğu şu şekilde tanımlanır [26].

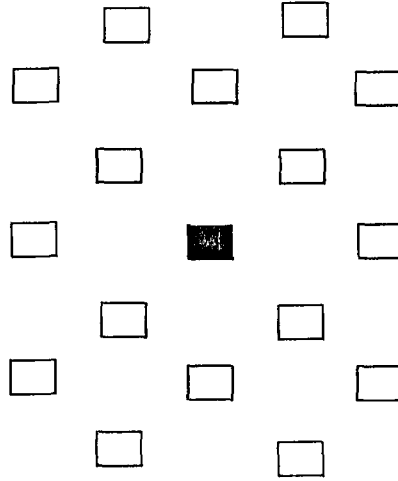
$$N_r(i,j) = \{ C(k,l) \mid \max(|i-k|, |j-l|) \leq r, 1 \leq i \leq M ; 1 \leq j \leq N \} \quad (2.57)$$

Burada komşuluğu gösteren r pozitif bir tamsayıdır ve her bir hücrenin kendisinden ne kadar uzaklıktaki hücreler tarafından doğrudan etkileneceğine işaret eder. Şekil 2.11'de de görülebileceği gibi $r = 1$ komşuluğunda yapı içerisindeki her bir hücre sadece çevresindeki hücreler tarafından etkilenirken (Buradaki etkilenme doğrudan bir etkilenmeyi vurgulamaktadır, gerçekte bu yapıdaki her bir hücre yapının hücre sayısına bağlı olarak belli bir zaman veya çevrim sonunda birbirlerini yayılım etkisi sonucu etkileyebilmektedirler.) $r = 2$ ve $r = 3$ komşuluklarında hücreler kendilerinden iki ve üç hücre uzaklıklarındaki hücreler tarafından da etkilenebileceğini göstermektedir [26].



Şekil 2.11. Hücresel yapay sinir ağlarında komşuluk


$r = 1$, $r = 2$ ve $r = 3$ olmak üzere üç farklı komşuluk durumunun bulunduğu bu gösterimlerde genellikle $r = 1$, $r = 2$ ve $r = 3$ komşuluklarına sırasıyla “3x3”, “5x5” ve “7x7” komşulukları da denir. Bir r -komşuluğu içerisinde $(2r+1)(2r+1)$ tane hücre bulunur. Komşuluk aynı zamanda simetri özelliğine de sahiptir. Yani $C(k,l) \in N_r(i,j)$ ise $C(i,j) \in N_r(k,l)$ dir. Hücrelerin bu şekilde karesel olarak sıralandığı bir yapının yanı sıra aynı komşuluk ilişkileri içerisinde ve karesel olmayan formatta da sıralanmaları mümkündür. Şekil 2.12’de altıgen olarak sıralanmış ki boyutlu bir Hücresel yapay sinir ağ yapısı gösterilmiştir.



Şekil 2.12. $r = 1$ komşuluğunda altıgen yapıya sahip hücrel yapay sinir ağı

2.3.2.3. Hücrel Yapay Sinir Ağlarının Devresel Gösterimi


Hücrel yapay sinir ağındaki bir hücreye karşılık gelen devresel eşdeğer Şekil 2.13'de gösterilmiştir. Hücrel yapay sinir ağının herhangi bir $C(i,j)$ hücresine karşılık gelen bu devrede u giriş, x durum ve y çıkışa karşılık gelmektedir. Bu $C(i,j)$ hücresine ait v_{xij} durum geriliminin başlangıç koşuluyla giriş gerilimi olan v_{uij} 'nin 1 den küçük veya eşit olduğu kabul edilmiştir. v_{yij} ise çıkış gerilimidir.



Şekil 2.13. Bir hücre yapısının devresel olarak gösterilmesi

Şekil 2.13'e bakılacak olursa buradaki $C(i,j)$ hücresi bir bağımsız gerilim kaynağı E_{ij} , bir bağımsız akım kaynağı I , bir doğrusal kapasite C , iki doğrusal direnç R_x ve R_y , komşu hücrelern iki katı kadar sayıda olan ve giriş kontrol gerilimi v_{ukl} ile çıkış kontrol gerilimi v_{ykl} tarafından geribesleme olarak kontrol edilen doğrusal gerilim kontrollü akım kaynaklarından meydana geldiği görülür. Burada $I_{xy}(i,j;k,l)$ ve $I_{xu}(i,j;k,l)$ gerilim kontrollü akım kaynaklarının karakteristikleri $C(k,l) \in N_r(i,j)$ komşuluğu altında $I_{xy}(i,j;k,l) = A(i,j;k,l)v_{ykl}$ ve $I_{xu}(i,j;k,l) = B(i,j;k,l)v_{ukl}$ olarak ifade edilirler. Her hücre içerisindeki tek doğrusal olmayan eleman parça-parça doğrusal $I_{yx} = (1/R_y)f(V_{xij})$ karakteristiğine sahip olan gerilim kontrollü akım kaynağıdır. $f(.)$ fonksiyonu Şekil 2.14 'de gösterilmiştir.

Bu devresel yapıdaki tüm parça-parça doğrusal fonksiyonlar işlemsel kuvvetlendiricili devreler yardımıyla kolaylıkla gerçekleştirilebilirler.



Şekil 2.14. Parça-parça doğrusal çıkış karakteristiği

Kirchoff gerilimler ve akımlar yasası uygulanarak bu hücreli devrenin eşitliği aşağıda gösterildiği gibi kolayca türetilir [25].

Durum eşitliği :

$$C \frac{dv_{xij}(t)}{dt} = -\frac{1}{R_x} v_{xij}(t) + \sum_{C(k,l) \in N_r(i,j)} A(i,j;k,l) v_{ykl}(t) + \sum_{C(k,l) \in N_r(i,j)} B(i,j;k,l) v_{ukl}(t) + I, 1 \leq i \leq M$$

$$; 1 \leq j \leq N \quad (2.58a)$$

Çıkış Eşitliği :

$$V_{yij}(t) = \frac{1}{2} (| v_{xij}(t)+1 | - | v_{xij}(t)-1 |), \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (2.58b)$$

Giriş Eşitliği :

$$v_{uij}(t) = E_{ij}, \quad 1 \leq i \leq M ; 1 \leq j \leq N \quad (2.58c)$$

Kısıtlama Durumları :

$$| v_{xij}(0) | \leq 1, \quad 1 \leq i \leq M ; 1 \leq j \leq N \quad (2.58d)$$

$$| v_{uij} | \leq 1, \quad 1 \leq i \leq M ; 1 \leq j \leq N \quad (2.58e)$$

Parametrik kabuller :

$$A(i,j;k,l) = A(k,l;i,j), \quad 1 \leq i \leq M ; 1 \leq j \leq N \quad (2.58f)$$

$$C > 0, R_x > 0. \quad (2.58g)$$

Buraya kadar anlatılanların ışığı altında ortaya çıkanları şu şekilde sıralayabiliriz.

Bir Hücresel yapay sinir ağındaki tüm merkezi hücreler aynı devre yapısı ve değerlerine sahiptirler. Bir merkezi hücre tanımlanan r komşuluğunda $(2r+1)^2$ kadar komşu hücreye sahip olan hücredir. Bunun dışında kalan hücreler ise sınır hücrelerdir. Bu şekilde tanımlanan Hücresel yapay sinir ağ yapıları doğrusal olmayan bir denklem takımı ile karakterize edilirler.

Hücresel yapay sinir ağındaki bir hücrenin dinamiklerini çıkış geribeslemesinin etkisini belirleyen $A(i,j;k,l)$ parametresi ile girişin kontrol etkisini belirleyen $B(i,j;k,l)$ parametreleri oluşturulur. Bu parametreler ayrıca $A(i,j;k,l)$ geribesleme ağırlık katsayısı ve $B(i,j;k,l)$ giriş ağırlık katsayısı olarak da adlandırılırlar.

2.3.2.4. Diferansiyel Denklemlerin Fark Denklemleri Olarak Gösterilmesi

Hücresel yapay sinir ağının görüntü işlemede neden kullanılabildiğini görmek amacıyla ilk olarak (2.58.a) diferansiyel denklemini, fark denklemi olarak yazalım. Bunun için h sabir bir zaman adımı olmak üzere $t = nh$ yazılacak olursa, $v_{xij}(t)$ ile ifade edilen diferansiyel denklemi fark denklemi biçiminde ifade edilebilir [22].

$$\frac{C}{h} [v_{xij}((n+1)h) - v_{xij}(nh)] = - \frac{1}{R_x} v_{xij}(nh) + \sum_{C(k,l) \in N_r(i,j)} A(i,j;k,l) v_{ykl}(nh) + \sum_{C(k,l) \in N_r(i,j)} B(i,j;k,l) v_{ukl} + I \quad 1 \leq i \leq M \quad ; \quad 1 \leq j \leq N \quad (2.59a)$$

Çıkış denkleminde de aynı işlemi gerçekleştirecek olursak :

$$v_{yij}(nh) = \frac{1}{2} (| v_{xij}(nh) + 1 | - | v_{xij}(nh) - 1 |) \equiv f(v_{xij}(nh)) , \quad 1 \leq i \leq M ; \quad 1 \leq j \leq N \quad (2.59b)$$

elde ederiz. (2.59.a) denkleminde

$$I_{ij} = \sum_{C(k,l) \in N_r(i,j)} B(i,j;k,l) v_{ukl} + I , \quad 1 \leq i \leq M ; \quad 1 \leq j \leq N \quad (2.60)$$

alınarak eşitlik şu şekilde yeniden yazılabilir :

$$v_{xij}(n+1) = v_{xij}(n) + \frac{h}{C} \left[\frac{-1}{R_x} v_{xij}(n) + \sum_{C(k,l) \in N_r(i,j)} A(i,j;k,l) v_{ykl}(nh) + I_{ij} \right],$$

$$1 \leq i \leq M ; 1 \leq j \leq N \quad (2.61)$$

Burada basitlik açısından zaman sabiti h “nh” ifadesinden çıkarılmıştır; Örneğin $v_{xij}(n) \equiv v_{xij}(nh)$ ve $v_{yij}(n) \equiv v_{yij}(nh)$ gibi. $v_{ykl}(n)$ için (2.59b) eşitliğini (2.61)’de yerine koyarsak,

$$v_{xij}(n+1) = v_{xij}(n) + \frac{h}{C} \left[\frac{-1}{R_x} v_{xij}(n) + \sum_{C(k,l) \in N_r(i,j)} A(i,j;k,l) f(v_{xkl}(n)) + I_{ij} \right], \quad 1 \leq i \leq M ;$$

$$1 \leq j \leq N \quad (2.62)$$

eşitliğini elde ederiz.

Son olarak elde edilen (2.62) eşitliği, $v_{xij}(n)$ ile ifade edilen bir görüntünün, $v_{xij}(n+1)$ ile ifade edilen başka bir görüntüye dönüşümünde kullanılan iki boyutlu bir filtre gibi düşünülebilir. Bu filtre (2.62)’de gösterilen $f(v_{xkl}(n))$ fonksiyonunun doğrusal olmamasından dolayı doğrusal değildir. Görüntü işlemede filtre, genellikle çalışılan uzamda değişmezdir, yani tüm i, j, k, l değerleri için $A(i,j;k,l) = A(i-k,j-l)$ ’dir.

Filtrenin özelliği (2.62)’de ki parametrelerle elde edilir. İstenilen görüntü dönüşümünün sağlanabilmesi için filtre parametrelerinin nasıl seçilmesi gerektiği günümüzde halen bir araştırma problemidir.

2.3.2.5. Hücresel Yapay Sinir Ağlarında Kararlılık

Hücresel yapay sinir ağlarının halen devam eden araştırma konularından birisi de kararlılık problemidir [36-37]. Başka bir deyişle Hücresel yapay sinir ağ çıkışlarının geçici rejimden sonra hangi koşullar altında sabit kararlı çıkış değerlerine ulaşacağıdır. Bu durumu;

$$\lim_{t \rightarrow \infty} v_{xij}(t) = \text{sabit}, \quad 1 \leq i \leq M ; 1 \leq j \leq N \quad (2.63)$$

veya geçici rejim sonrasında durum görüntüsünün sabit bir değere ulaşması durumunu göz önüne alarak

$$\lim_{t \rightarrow \infty} \frac{dv_{xij}(t)}{dt} = 0, 1 \leq i \leq M; 1 \leq j \leq N \quad (2.64)$$

şeklinde de ifade edebiliriz.

Bu konuda yapılan çalışmalar göstermiştir ki; A geribesleme ağırlık katsayı matrisinin simetrik olması durumunda aksi ispat edilemediği için devre parametrelerinin,

$$A(i,j;i,j) > \frac{1}{R_x} \quad (2.65)$$

koşulunu sağlaması durumunda

$$\lim_{t \rightarrow \infty} |v_{xij}(t)| \geq 1, 1 \leq i \leq M; 1 \leq j \leq N \quad (2.66)$$

veya eşdeğeri

$$v_{yij}(t) = \pm 1, 1 \leq i \leq M; 1 \leq j \leq N \quad (2.67)$$

koşulları sağlanmış olur.

Bu da Hücrel yapay sinir ağı için devrenin osilasyon yapmayacağını veya en azından kaotik bir duruma geçmeyeceğini göstermesi açısından oldukça önem taşımaktadır. Bu durum hücrel sinir ağının çıkışlarının sadece ikili değerlerden oluşacağını garanti etmektedir.

2.3.2.5.1. Hücresel Yapay Sinir Ağlarının Sürekli Zaman Analizi

Hücresel yapay sinir ağı dinamik bir ağ olduğundan durum ve buna doğrusal olmayan bir fonksiyonla bağlı olan çıkış, sürekli bir değişim içerisinde. Hücresel yapay sinir ağındaki bu görüntü dönüşümünün nasıl çalıştığını daha rahat anlayabilmek için (2.58a) eşitliğini integral formunda aşağıda gösterildiği gibi tekrar yazalım [26] ;

$$v_{xij}(t) = v_{xij}(0) + \frac{1}{C} \int_0^t \left[\frac{-1}{R_x} v_{xij}(\tau) + f_{ij}(\tau) + g_{ij}(u) + I \right] d\tau, \quad 1 \leq i \leq M; 1 \leq j \leq N \quad (2.68)$$

Burada,

$$f_{ij}(t) = \sum_{C(k,l) \in N_r(i,j)} A(i, j; k, l) v_{ykl}(t) \quad (2.69a)$$

ve

$$g_{ij}(u) = \sum_{C(k,l) \in N_r(i,j)} B(i, j; k, l) v_{ukl} \quad (2.69b)$$

olarak yeniden düzenlenmişlerdir.

Burada yazılan (2.68) eşitliğinden daha rahat görülmektedir ki $v_{xij}(t)$ görüntünün herhangi bir t anındaki durumunu temsil etmektedir. Bu durum başlangıç koşulu olarak verilen görüntü $v_{xij}(0)$ ve hücresel yapay sinir ağının dinamik kurallarına bağlıdır. Böylece buradan da açıkça görülebileceği gibi hücresel yapay sinir ağları, bir başlangıç görüntüsünün herhangi bir t anındaki dinamik dönüşümünü elde etmek için kullanılabilir. Özel olarak burada $t \rightarrow \infty$ olması durumunda durum değişkeni tam kararlı durumda v_{xij} bir sabite ve çıkış v_{yij} ise $+1$ ve -1 değerlerinden herhangi birisine gitmektedir. Karalılık koşullarının sağlanmaması durumunda ise osilasyon ve kaotik durumları ortaya çıkmaktadır. Bu durumu daha rahat anlayabilmek için hem kararlı durum ve hem de kaotik yapılarına sahip iki ayrı hücresel yapay sinir ağ yapısını birer örnekle inceleyelim.

2.3.2.6. Hücresel Yapay Sinir Ağlarında Öğrenme

HYSA'da istenilen herhangi bir işi yerine getirmesi için henüz analitik olarak geliştirilmiş bir öğrenme algoritması yoktur. Başka bir deyişle istenen görüntü işleme işlevini yerine getirecek olan bağlantı ağırlık katsayılarını belirlemek HYSA'da önemli bir araştırma konusu olmaya halen devam etmektedir. Burada geliştirilen ve tez boyunca yapılan uygulamaların çoğunda kullanılan bir Dinamik Ardışıl Algılayıcı Öğrenme Algoritması olan (Recurrent Perceptron Algorithm : RPLA) anlatılacaktır. Ancak bu algoritmanın nasıl çalıştığına bakmadan önce HYSA'yı karakterize eden denklemleri bu algoritma boyunca kullanacağımız haliyle yeniden düzenleyelim.

$$\dot{x}_{i,j} = -S \cdot x_{i,j} + \sum_{k,l \in \{-1,0,1\}} A_{k,l} \cdot y_{(i+k),(j+l)} + \sum_{k,l \in \{-1,0,1\}} B_{k,l} \cdot u_{(i+k),(j+l)} + I, \quad (2.70)$$

$$y_{i,j} = f[x_{i,j}] = \frac{1}{2} \cdot (|x_{i,j}(n)+1| - |x_{i,j}(n)-1|) \quad (2.71)$$

HYSA, iki boyutlu yapılarından dolayı özellikle görüntü işleme alanlarında oldukça fazla kullanım alanlarına sahiptirler. Bir hücrenin temel fonksiyonu herhangi bir giriş görüntüsünü istenilen amaca uygun olarak bir çıkış görüntüsüne dönüştürmesidir. Ele alınan görüntüler sayısal olduklarından HYSA'nın ayrık denklemlerini yazalım :

Ayrık zamanlı HYSA'yı temsil eden denklem şu şekilde gösterilir [35]:

$$x_{i,j}(n+1) = \sum_{C(k,l) \in N_r(i,j)} A(i,j;k,l) y_{k,l}(n) + \sum_{C(k,l) \in N_r(i,j)} B(i,j;k,l) u_{k,l}(n) + I_{i,j}, \quad (2.72)$$

$$y_{i,j}(n) = f[x_{i,j}(n)] = \frac{1}{2} (|x_{i,j}(n)+1| - |x_{i,j}(n)-1|) \quad (2.73)$$

Burada $u_{i,j}$ -1 ve $+1$ değerleri arasında sayılar alabilen girişi, $y_{i,j}$ çıkışı ve $x_{i,j}$ ise durumu gösterirken ; $A_{i,j}$ geribesleme ağırlık katsayılarına, $B_{i,j}$ giriş ağırlık

katsayılarına ve I_{ij} ise her hücre için genellikle aynı olan eşik seviyesine karşılık gelmektedir.

Buna göre (2.72)'te gösterilen bu fark denklemini görüntü işlemede doğrusal olmayan iki boyutlu filtre gibi kabul edebiliriz. Bu filtre $x_{ij}(n)$ değerinden $x_{ij}(n+1)$ değerine dönüşüm yapan bir filtre olacaktır. Başka bir deyişle bu dönüşüm tek adım olarak düşündüğümüz zaman bu doğrusal olmayan filtre $x_{ij}(0)$, u_{ij} , A_{ij} , B_{ij} , ve I_{ij} değerlerinin bilinmesi durumunda seçilen komşuluk kuralına ve $x_{ij}(0)$ değerine bağlı olarak herhangi bir n anında $y_{ij}(n)$ çıkışının bulunmasına olanak sağlayacaktır. Dikkat edilecek olursa burada iteratif bir filtreleme yapılmaktadır. Bu iteratif filtreleme sayesinde bir görüntüdeki yerel bilgilerin yanı sıra iterasyon sayısına bağlı olarak global bilgilerin de ortaya çıkarılması sağlanmaktadır. Tek bir iterasyonda görüntü üzerindeki her nokta etkilenirken, iterasyon sayısı arttıkça birbirinden oldukça uzaktaki noktaların birbirlerini etkilemeleri mümkün olmaktadır.

2.3.2.6.1. RPLA Öğrenme Algoritması

RPLA algoritması burada 3x3 boyutundaki bağlantı ağırlık katsayıları için tanımlanacaktır;

$$A = \begin{bmatrix} A_{-1,-1} & A_{-1,0} & A_{-1,1} \\ A_{0,-1} & A_{0,0} & A_{0,1} \\ A_{1,-1} & A_{1,0} & A_{1,1} \end{bmatrix} \quad B = \begin{bmatrix} B_{-1,-1} & B_{-1,0} & B_{-1,1} \\ B_{0,-1} & B_{0,0} & B_{0,1} \\ B_{1,-1} & B_{1,0} & B_{1,1} \end{bmatrix}$$

olarak kabul edilmişlerdir. Buradan şu tanımlamalar yapılabilir;

$$A_{-1,-1} = A_{1,1} = a_1, \quad A_{-1,0} = A_{1,0} = a_2, \quad A_{-1,1} = A_{1,-1} = a_3, \quad A_{0,1} = A_{0,-1} = a_4, \quad A_{0,0} = a_5$$

$$B_{-1,-1} = B_{1,1} = b_1, \quad B_{-1,0} = B_{1,0} = b_2, \quad B_{-1,1} = B_{1,-1} = b_3, \quad B_{0,1} = B_{0,-1} = b_4, \quad B_{0,0} = b_5$$

Bu tanımlamalardan sonra A ve B matrisleri yeniden düzenlenirse :

$$\mathbf{A} = \begin{bmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_4 \\ a_3 & a_2 & a_1 \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} b_1 & b_2 & b_3 \\ b_4 & b_5 & b_4 \\ b_3 & b_2 & b_1 \end{bmatrix}$$

elde edilir. Dikkat edilecek olursa yeniden düzenlenen bu matrislerde \mathbf{A} matrisi tamamen kararlılık için simetrik seçilirken, \mathbf{B} matrisi ise hesaplama kolaylığı açısından simetrik seçilmiştir.

Bu öğrenme algoritmasında amaç istenilen görüntü işleme işlevini yerine getirecek bu ağırlık katsayılarını ve I eşik seviyesini elde etmektir. Bunun için bu değerlerin oluşturduğu bir w vektörü şu şekilde tanımlanabilir;

$$\mathbf{w} = [\mathbf{a}^T \ \mathbf{b}^T \ I]^T = [a_1 a_2 a_3 a_4 a_5 b_1 b_2 b_3 b_4 b_5 I]^T \quad (2.74)$$

Buradaki öğrenme algoritmasında hata fonksiyonunun türevine ihtiyaç yoktur ve giriş iki kısımdan meydana gelmiştir. Bunlar, HYSAs'nın girişleri ve başlangıç durum değerleridir. Genelleştirme için bu giriş vektörleri şu şekilde tanımlanabilir. Dış giriş vektörü $\mathbf{v}_u = [\dots, u_{ij}, \dots]^T \in \mathbf{R}^m$ ve başlangıç durum vektörü $\mathbf{v}_x = [\dots, x_{ij}(0), \dots]^T \in \mathbf{R}^m$ olmak üzere, sistemin giriş vektörü $\mathbf{v} = [\mathbf{v}_u^T \ \mathbf{v}_x^T]^T$ olarak gösterilsin. HYSAs, bu giriş vektöründen w ağırlık katsayı değerlerini kullanarak $\mathbf{y} = [\dots, y_{ij}(t), \dots]^T \in \mathbf{R}^m$ çıkış vektörünü elde eder. Yani giriş vektör uzayıyla, çıkış vektör uzayı arasında cebrik bir dönüşüm tanımlar.

RPLA eğitici bir öğrenme algoritmasıdır. Buna göre giriş ve istenen çıkış kümelerini bir \mathbf{d} vektörü kullanarak şu şekilde tanımlanabilir;

$$\mathbf{d} = P(\mathbf{v}) : \{ (\mathbf{v}^1, \mathbf{d}^1), (\mathbf{v}^2, \mathbf{d}^2), \dots, (\mathbf{v}^N, \mathbf{d}^N) \} \quad (2.75)$$

Burada \mathbf{v}^s ve \mathbf{d}^s eğitim setlerinden s . örneğe ait giriş ve istenen çıkış çiftlerine karşılık gelmektedir. Hata fonksiyonu ε $[\mathbf{w}]$ ise istenen çıkış ile $y_{ij}(\infty)$ olarak gösterilen gerçek çıkış (kararlı durum çıkışı) arasındaki farkın bir ölçüsüdür. Amaç, bu hata fonksiyonunu minimize edecek olan w ağırlık katsayılarının elde edilmesidir. Her bir giriş ve çıkış çifti de göz önünde bulundurularak hata fonksiyonu şu şekilde tanımlanabilir;

$$\epsilon [\mathbf{w}] = \sum_{s=1}^N \epsilon^s [\mathbf{w}] = \sum_s \sum_{i,j} (y^s_{i,j}(\infty) - d^s_{i,j})^2 \quad (2.76)$$

Bu aşamadan sonra problem, kısıtlamaları (2.71) ve (2.72) denklemleri ve $a_5 > S$ olan kısıtlamalı bir optimizasyon problemine dönüşmektedir. Böyle çıkışların sadece +1 ve -1 değerlerinde olması garanti edilmektedir.

$\epsilon [\mathbf{w}]$ 'daki sabit terimler ihmal edilip yeniden düzenlenirse,

$$\epsilon [\mathbf{w}] = \sum_{i,j,s} y^s_{i,j}(\infty) \cdot (y^s_{i,j}(\infty) - d^s_{i,j}) = \sum_{(i,j,s) \in D^+} y^s_{i,j}(\infty) - \sum_{(i,j,s) \in D^-} y^s_{i,j}(\infty) \quad (2.77)$$

eşitliği elde edilir. Bu eşitlik RPLA algoritmasının oluşturulmasını daha anlaşılır kılmaktadır.

Bu eşitlikte, $D^+ = \{ (i,j,s) \mid y^s_{i,j}(\infty) = -d^s_{i,j} = 1 \}$ ve $D^- = \{ (i,j,s) \mid y^s_{i,j}(\infty) = -d^s_{i,j} = -1 \}$ şeklindedir. Yani buradaki D^+ ve D^- bölgeleri gerçek çıkışlar ile istenen çıkışlar arasındaki uyuşmanın ölçütünün birer karşılığıdır.

Burada tanımlanan hata fonksiyonunda parça-parça doğrusal çıkış fonksiyonunun türevlenebilir bir fonksiyon olmamasından dolayı gradyant yöntemleri bu problem için kullanılamaz. (2.70) ile gösterilen eşitlik kararlı durum çıkışı için $S \cdot x_{ij}$ ifadesi eşitliğin sol tarafına alınıp s. örnek için yeniden yazılırsa,

$$S \cdot x_{ij}(\infty) = [Y^s_{ij}]^T \cdot \mathbf{w} = \sum_{k,l \in \{-1,0,1\}} A_{k,l} \cdot y_{(i+k),(j+l)}(\infty) + \sum_{k,l \in \{-1,0,1\}} B_{k,l} \cdot u_{(i+k),(j+l)}(\infty) + I; \quad (2.78)$$

elde edilir. Burada Y^s_{ij} $C(i,j)$ hücrelerini süren toplam giriş olarak ifade edilebilir ve şu şekilde gösterilir.

$$\mathbf{Y}_{ij}^s = [[\mathbf{y}_{ij}^s]^T [\mathbf{u}_{ij}^s]^T \mathbf{1}]^T \quad (2.79)$$

A ve B matrislerinin tam simetrik olduklarını bildiklerimizden \mathbf{y}_{ij}^s ve \mathbf{u}_{ij}^s matrisleri

$$\mathbf{y}_{ij}^s = [\mathbf{y}_{i-1,j-1}^s(\infty) + \mathbf{y}_{i+1,j+1}^s(\infty) \quad \mathbf{y}_{i-1,j}^s(\infty) + \mathbf{y}_{i+1,j}^s(\infty) \quad \mathbf{y}_{i-1,j+1}^s(\infty) + \mathbf{y}_{i+1,j-1}^s(\infty) \\ \mathbf{y}_{i,j-1}^s(\infty) + \mathbf{y}_{i,j+1}^s(\infty) \quad \mathbf{y}_{ij}^s(\infty)]^T \quad (2.80)$$

$$\mathbf{u}_{ij}^s = [\mathbf{u}_{i-1,j-1}^s + \mathbf{u}_{i+1,j+1}^s \quad \mathbf{u}_{i-1,j}^s + \mathbf{u}_{i+1,j}^s \quad \mathbf{u}_{i-1,j+1}^s + \mathbf{u}_{i+1,j-1}^s \quad \mathbf{u}_{i,j-1}^s + \mathbf{u}_{i,j+1}^s \quad \mathbf{u}_{ij}^s] \quad (2.81)$$

şeklinde tanımlanabilirler.

Burada \mathbf{Y}_{ij}^s vektörünün ilk beş teriminin geribesleme ağırlık katsayı matris değerlerinin bir türevlenebilir bir fonksiyonu olmadığına dikkat etmesi gerekir. Yine burada önemli bir nokta, verilen \mathbf{w} ağırlık katsayıları vektörü ile girişlere bağlı olarak istenilen işlevi yerine getirecek birden fazla çözümün olabileceğidir. Denklemin denge noktalarındaki bu çözümler seçilen başlangıç durum değerlerine bağlıdır.

Sonuç olarak (2.82)'te verilen fark denklemi ile ağırlık katsayısı bağlantı vektörü \mathbf{w} istenilen işlev yerine getirilinceye kadar adım adım uyarlanır. Böylece bu şekildeki fark denklemleriyle verilen ve başlangıç koşullarıyla gerçek çıkışların istenilen çıkışlara ulaşması için ağırlık katsayı bağlantılarının adım adım uyarlanarak bulunmasını sağlayan bu algoritmaya RPLA algoritması adı verilir .

$$\mathbf{w}(n+1) = [\mathbf{w}(n) - \epsilon(n) \cdot \gamma [\mathbf{w}(n)]]^+ \quad (2.82)$$

Burada, $\gamma [\mathbf{w}(n)]$ vektörü şu şekilde tanımlanır :

$$\gamma [\mathbf{w}(n)] = \left(\sum_{(i,j,s) \in D^+} \mathbf{Y}_{ij}^s(n) - \sum_{(i,j,s) \in D^-} \mathbf{Y}_{ij}^s(n) \right) \quad (2.83)$$

$\epsilon(n)$ öğrenme hızını belirleyen bir parametredir ve zamana bağlı bir fonksiyon seçilebileceği gibi genellikle zamandan bağımsız çok küçük pozitif bir sayı olarak seçilir. RPLA çıkışların +1 ve -1 değerlerine yakınsamalarını garantileyen $a_5 > S$ koşulu altında başlatılır. Her adımda $y_{ij}^s(\infty)$ kararlı durum vektörü, (2.70) ile gösterilen diferansiyel denklemler giriş vektörü v_u^s ve uyarlanmış bağlantı ağırlık katsayıları vektörü için seçilen başlangıç durum vektörü v_x^s bağlı olarak çözülür. (2.82)' te gösterilen $[w]^+$, w bağlantı ağırlık katsayı vektörünün $\Lambda = \{ w \in \mathbf{R}^{11} \mid a_5 > S \}$ kümesinin bir elemanı olduğunu gösterir. Bu da kararlı durum çıkışlarının +1 ve e-1 değerlerine gideceklerini garanti eder. $[\cdot]^+$ şu şekilde tanımlanır:

$$w(n) \in \Lambda \text{ ise } [w(n)]^+ = w(n) \text{ ve } w(n) \notin \Lambda \text{ ise } [w(n)]^+ = K_n \cdot w(n) \quad (2.84)$$

Burada $K_n = \mu \cdot \frac{A}{a_5(n)}$ şeklinde tanımlıdır. $\mu > 1$ olan ve genellikle 1.5 olarak seçilen bir sabittir.

2.3.2.7. Hüresel Yapay Sinir Ağlarında Konvolüsyon İlişkisi

(2.85)'de verilen ve ayrı zamanlı hüresel yapay sinir ağını ifade eden formülde A ve y arasındaki ilişki ile B ve u arasındaki ilişki aynı olup iki boyutlu bir konvolüsyon ilişkisidir.

$$X_{ij}(n+1) = \sum_{(k,l) \in N_r(i,j)} A_{i,j;k,l} \cdot y_{k,l}(n) + \sum_{(k,l) \in N_r(i,j)} B_{i,j;k,l} \cdot u_{k,l}(n) + I_{i,j} \quad (2.85)$$

$$x(n+1) = A * y(n) + B * u + I \quad (2.86)$$

Buna göre (2.86) yeniden düzenlenecek olursa

$$x_{ij}(n+1) = \sum_{k \in N_r(i,j)} \sum_{l \in N_r(i,j)} \hat{A}_{i,j} \cdot y_{i-k,j-l}(n) + \sum_{k \in N_r(i,j)} \sum_{l \in N_r(i,j)} \hat{B}_{i,j} \cdot u_{i-k,j-l} + I \quad (2.87)$$

Ancak burada dikkat edilmesi gereken iki önemli nokta vardır. Birincisi, bu ifadenin işlenecek olan görüntülerinin sınır değerlerinin tamamen sıfır olarak seçildiği kabulü altında bu konvolüsyon toplamının yazılabileceğidir. İkincisi \hat{A} ve \hat{B} değerlerinin; (2.86)'dekiler ile ilişkisinin $\hat{A}_{i,j} = A_{i,j}$ ve $\hat{B}_{i,j} = B_{i,j}$ şeklinde olması gerektiğidir. Buna göre (2.87) yeniden yazılacak olursa:

$$x_{ij}(n+1) = \sum_{k \in N_r(i,j)} \sum_{l \in N_r(i,j)} \hat{A}_{-i,-j} \cdot y_{i-k,j-l}(n) + \sum_{k \in N_r(i,j)} \sum_{l \in N_r(i,j)} \hat{B}_{-i,-j} \cdot u_{i-k,j-l} + I \quad (2.88)$$

elde edilir.

2.3.2.8. Hücresel Yapay Sinir Ağlarında Yayılım Özelliği

Tek adımlık filtreleme sonrasında $x(n+1)$ olarak gösterilen bir görüntünün piksel değerleri doğrudan $x(n)$ 'in piksel değerlerinden, uygun $N_r(i,j)$ komşuluk ilişkisi içinde elde edilirler. Pratik açıdan yaklaşılacak olursa, bu komşuluk her zaman mümkün olduğunca küçük seçilir. Tipik seçim 3×3 'lük bir komşuluk olmasına rağmen istenilen dönüşüme uygun olarak daha büyük komşuluklar da seçilebilmektedir. Burada $x(n)$ değerinden $N_r(i,j)$ komşuluğu içerisinde tek adımlık bir filtreleme sonrasında $x(n+1)$ elde edilmesi görüntünün yalnızca yerel birtakım özelliklerinin ortaya çıkarılmasında etkili olabilecektir. Başka bir deyişle bu tek adımlık filtreleme sonucunda görüntüdeki her piksel seçilen komşuluk değerlerine bağlı olarak yalnızca çevresindeki pikseller tarafından etkilenecektir[38].

Görüntünün global özelliklerinin önemli olduğu durumlarda, görüntüden birtakım ek global bilgilerin de ortaya çıkarılması için yukarıdaki tek adımlık filtreleme iteratif olarak n defa tekrarlanabilir. Bu n defalık tekrar sonucunda görüntüdeki her bir piksel yine seçilen komşuluk ilişkisine bağlı olarak görüntü üzerindeki herhangi bir piksel tarafından dolaylı olarak etkilenecektir. Bu durum görüntünün yerel özellikleri dışında global özelliklerinin de ortaya çıkarılması açısından oldukça önemlidir. İteratif filtrelemenin bu özelliği “yayılım özelliği” olarak da adlandırılır. Bu özellik n iterasyon sonrasında çıkış görüntüsünün piksel değerlerinin, giriş görüntüsünün daha büyük bir komşu bölgesi tarafından dolaylı olarak etkilenebildiğine işaret etmektedir. $x(0)$ giriş görüntümüzün ilk değerini göstermek üzere bu özellik (2.85)'de $x(n)$ ' in iteratif olarak $x(0)$ ' a doğru yerine konulmasıyla ifade edilebilir. Sonuçta bu durum ilk baştaki $x(0)$ giriş görüntüsünün. (2.86) eşitliğinin de bazı doğrusal olmayan fonksiyonlar içermesinden dolayı, istenilen komşuluk ilişkisi içerisinde doğrusal olmayan bir fonksiyondan geçirilmiş bir durumu olarak ele alınabilir. Buna göre yazılacak bu eşitlik rahatça şu şekilde gösterilebilir;

$$x_{i,j}(n) = \sum_{(k,l) \in N_{nr}(i,j)} g^n_{ijkl,(i,j),(k,l)}(x_{i,j}(0)) \quad (2.89)$$

(2.89)'daki bu eşitlikte $g^n_{ijkl,(i,j),(k,l)}$ ve n değerlerine bağlı olan doğrusal olmayan bir fonksiyondur. Burada dikkat edilmesi gereken nokta $N_{nr}(i,j)$ komşuluğunun, $N_r(i,j)$ komşuluğundan n defa daha büyük olduğu ve bu büyüklük değerinin de iterasyon sayısı n 'e bağlı olduğudur. Bu eşitlikte dikkat edilecek olursa iterasyon sayısı n yeterince büyük olduğu zaman $N_{nr}(i,j)$ komşuluğu, sonunda, (i,j) ve r 'den bağımsız olarak bütün görüntüyü kaplayacak bir duruma gelecektir. Bu yüzden iteratif filtrelerin yayılım özelliği görüntülerde bazı global özelliklerin ortaya çıkarılmasını mümkün kılmaktadır.


Sonuçta hücrel yapay sinir ağları bu şekilde dinamik bir ağ yapısı gösterdiğinden zamanın her anında çıkış görüntüsü değişim göstermekte ve belli bir zaman sonrasında ise sabit bir değerde kalarak istenilen kararlı durum çıkışına ulaşmaktadır. Bu dinamik yapıdaki her çevrim sonrasında seçilen komşuluk ilişkisine de bağlı olarak her piksel çevresindeki pikselleri etkilemekte ve çevrim sayısı arttıkça her görüntünün her bölümündeki piksellerin birbirlerini etkilemeleri sağlanmaktadır.

2.3.3. MARKOV RASTGELE ALANLARI-HÜCRESEL YAPAY SİNİR AĞLARI MODELLENMESİ


Bu bölümde yapılan tez çalışmasının son kısmı olan MRA-HYSA modeli hakkında bilgi verilecektir. Bölüm 2.2'de bir görüntünün markov rastgele alanları ile nasıl modellendiği anlatılmıştı. Burada MRA ile modellenen ve işlenen görüntünün hücrel yapay sinir ağları ile modellenip daha iyi sonuç elde edilmesi amaçlanmaktadır.

Daha önceden elde edilen MRA çıktısı HYSA'nın girişi olarak alınır. RPLA öğrenme algoritması ile giriş görüntüsü eğitilerek w ağırlık katsayıları bulunur. Elde edilen bu ağırlık katsayıları test işleminde yerine konularak diğer görüntüler için sonuçlar elde edilir[6].

Bu anlatılanlar, aşağıdaki gibi blok şema halinde gösterilebilir:



(a)



(b)

Şekil 2.15. MRA-HYSA Modeli blok şeması


Yukarıdaki blok şemada da görüldüğü gibi MRA ve HYSA kaskad bağlanarak yeni bir algoritma yazılmıştır. MRA-HYSA modeli MRA'ya göre daha karmaşık bir yapıya sahiptir. Ancak yapılan bazı uygulamalarda MRA'ya göre daha iyi sonuçlar elde edilmiştir. Bu uygulamalar bulgular bölümünde gösterilmiştir.

2. BULGULAR


3.1. MARKOV RASTGELE ALANLARI İLE MODELLENEN BİYOMEDİKAL GÖRÜNTÜLERİN BENZETİM SONUÇLARI

Bu bölümde bölüm 2.2’de MRA ile modellenen biyomedikal işaretler için benzetim sonuçları gösterilecektir. Bu amaçla, benzetimi yapılacak işaretler için MATLAB paket programı yardımıyla bir program yazılmıştır. Bu çalışmada farklı piksel değerlerine sahip biyomedikal sentetik görüntüler kullanılmıştır.


Birinci görüntü 265×272 piksele sahip kan hücresi görüntüsüdür. Bu görüntüye ortalaması (mean) 0 (sıfır) ve gücü (varyans) 9 olan beyaz gauss gürültüsü eklenmiştir. Parametre vektörü $\theta = [0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0.643 \ 0.120 \ -0.042 \ 0.142 \ 0 \ 0 \ 0 \ 0]$ olarak elde edilmiştir.



(a) Orjinal görüntü




(b) Gürültülü görüntü ($\sigma = 9$)




(c) MRA’lı bölütlenmiş görüntü (Bölüt sayısı = 8)

Şekil 3.1. Kan hücresi görüntüsü


İkinci görüntü 279×392 piksele sahip kan hücresi görüntüsüdür. Bu görüntüye ortalaması 0 (sıfır) ve gücü 9 olan beyaz gauss gürültüsü eklenmiştir. Parametre vektörü $\theta=[0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0.1075 \ 0.02855 \ 0.06855 \ 0.1284 \ 0 \ 0 \ 0 \ 0]$ olarak elde edilmiştir.



(a) Orjinal görüntü




(b) Gürültülü görüntü ($\sigma = 9$)




(c) MRA'lı bölütlenmiş görüntü (Bölüt sayısı = 8)

Şekil 3.2. Enamel hücresi görüntüsü


Üçüncü görüntü 178×178 piksele sahip enamel hücresi görüntüsüdür. Bu görüntüye ortalaması 0 (sıfır) ve gücü 4 olan beyaz gauss gürültüsü eklenmiştir. Parametre vektörü $\theta = [0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ -0.1347 \ 0.3056 \ 0.1253 \ 0.3646 \ 0 \ 0 \ 0 \ 0 \ 0]$ olarak elde edilmiştir.



(a) Orjinal görüntü




(b) Gürültülü görüntü ($\sigma = 4$)




(c) MRA'li bölütlenmiş görüntü (Bölüt sayısı = 8)

Sekil 3.3. Bakteri hücresi görüntüsü


Dördüncü görüntü 128×128 piksele sahip kaburga görüntüsüdür. Bu görüntüye ortalaması 0 (sıfır) ve gücü 4 olan beyaz gauss gürültüsü eklenmiştir. Parametre vektörü $\theta = [0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ -0.0188 \ 0.1354 \ 0.0543 \ 0.2139 \ 0 \ 0 \ 0 \ 0 \ 0]$ olarak elde edilmiştir.



(a) Orjinal görüntü




(b) Gürültülü görüntü ($\sigma = 4$)




(c) MRA'lı bölütlenmiş görüntü (Bölüt sayısı = 8)

Şekil 3.4. Kaburga görüntüsü


Beşinci görüntü 238×270 piksel değerine sahip bonemarr görüntüsüdür. Bu görüntüye ortalaması 0 (sıfır) ve gücü 4 olan beyaz gauss gürültüsü eklenmiştir. Parametre vektörü $\theta = [0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ -0.0188 \ 0.1354 \ 0.0543 \ 0.2139 \ 0 \ 0 \ 0 \ 0 \ 0]$ olarak elde edilmiştir.



(a) Orjinal görüntü



(b) Gürültülü görüntü ($\sigma = 4$)




(c) MRA'lı bölütlenmiş görüntü (Bölüt sayısı =8)

Şekil 3.5. Bonemarr görüntüsü


MRA ile modellenen görüntülerin benzetim sonuçlarına bakıldığında çok iyi sonuçların elde edildiği görülmektedir. Yukarıda da görüldüğü gibi gürültü büyük ölçüde temizlenmiş ve orjinal görüntüye yakın sonuçlar elde edilmiştir.

3.2. MRA-HYSA YAPISI İLE MODELLENEN BİYOMEDİKAL GÖRÜNTÜLERİN BENZETİM SONUÇLARI

Bu bölümde bölüm 2.4'de MRA-HYSA yapısı ile modellenen biyomedikal işaretler için benzetim sonuçları gösterilecektir. Bu amaçla, benzetimi yapılacak işaretler için MATLAB paket programı yardımıyla bir program yazılmıştır. RPLA öğrenme algoritmasıyla bakteri hücresi görüntüsü için w ağırlık katsayıları bulunmuş daha sonra bu değerlere göre farklı iki görüntü için test çıktıları gösterilmiştir.



(a) Orjinal görüntü




(b) Gürültülü görüntü ($\sigma = 4$)





(c) MRA-HYSA çıkış görüntüsü

Şekil 3.6. MRA –HYSA yapısı için test-1 görüntüsü



(a) Orjinal görüntü

(b) Gürültülü görüntü ($\sigma = 9$)

(c) MRA-HYSA çıkış görüntüsü

Şekil 3.7. MRA –HYSA yapısı için test-2 görüntüsü

MRA-HYSA ile modellenen görüntülerin benzetim sonuçları yukarıda görülmektedir. MRA ile gürültü büyük ölçüde temizlenmesine karşın çıkış görüntüleri orjinal görüntüdeki bazı ayrıntıları yakalayamamaktadır. MRA-HYSA yapısı ile MRA ile gürültüsü temizlenen bozulmuş görüntünün, HYSA'daki öğrenme algoritması ile istenilen görüntü ile eğitilerek orjinal görüntüye daha yakın sonuçlar elde edilmiştir.

TARTIŞMA VE SONUÇ

Bu çalışmada Markov rastgele alanları ve Hücrenel yapay sinir ağları ile biyomedikal görüntü işleme yapılmıştır. Görüntü işlemede Markov rastgele alanları ile hesaplama yapmak için iki temel aşama vardır. Bunlardan birincisi sistemi modelleme, ikincisi ise en-iyilemenin yapılmasıdır. Örneğin giriş veri görüntüsü Y olsun ve Y 128×128 'lik bir görüntü olsun. Çıkış verisi ise X olsun. Burada Gibbs dağılımı kullanarak bölütleme yapıyor olalım. Demek ki elimizde $128 \times 128 = 16384$ adet piksel vardır. Gibbs dağılımı için ortaya konacak enerji fonksiyonu 16384 adet Y verisini ve 16384 adet X verisini içeren bir fonksiyon haline gelecektir. Y verisi bilindiğine göre enerji fonksiyonu 16384 adet değişkeni içerecektir. Bu enerji fonksiyonunun enazlanması gerekmektedir. Enazlama sonucunda ortaya çıkan minimum noktayı veren X dizisi problemin çözümü olacaktır.

Örnekte de görüldüğü üzere ilk önce yapılması gereken pikseller arasındaki ilişkiye dayalı bir modelin ortaya konulmasıdır. İkinci bölümde geniş bir şekilde ele alınan bu modelleme her bir işlemde farklılık gösterdiği ve henüz bu tarz algoritmaya dayalı yaklaşımlarda bir öğrenme yapısı olmadığı için uzun süreli bir çalışma gerekmektedir. Bu çalışmanın özünü nitelik veya özellik çıkarma olarak (feature extraction) ifade edebiliriz. Günümüze kadar gelen yazınlar ve birikimler sonucu bu tespitler gerçekte çok iyi neticeler vermektedir. Buna karşın her zaman aşılması gereken temel matematiksel sorun en-iyileme problemi olmaktadır. Hızlı olması istenen sonuçlar için yerel sonuçların (minimum) bulunması yaklaşımı yapılmaktadır. Fakat bu yaklaşımla Markov rastgele alan modelinin sahip olduğu güçten ödün verilmektedir. Bu durum konuya özel çözümlerin gelişmesine sebep olmaktadır. MRA ile modellenen işaretlerin benzetim sonuçlarına bakıldığında çok iyi sonuçlar elde edildiği görülmektedir. İşarete çok fazla miktarda Gauss gürültüsü eklenmesine karşın, gürültü tamamen temizlenmiş orjinal işarete yakın sonuçlar elde edilmiştir.

Gerçek zamanlı uygulamalarda gerekli hesap gücünü aşmak, görüntü işlemede geniş bir şekilde kullanılan ve günümüzde bu yönde geniş bir eğilimin olduğu hücrenel sinir ağları yapısının incelenmesiyle olabilir. Hücrenel sinir ağları öğrenme yeteneğine sahip olduğu için modellenmenin gerekmediği bir yaklaşımdır. Belli sayıda giriş ve do çıkış çiftlerini kullanılarak eğitilen bir hücrenel sinir ağı daha sonra verilen girişler için doğru sonuçlar üretebilmektedir. Fakat sistem karmaşıklığı artırıldıkça daha iyi sonuçlar vermektedir. Örneğin tek komşulu ve basit bir hücrenel sinir ağı yapısına ne kadar iyi bir öğretim yapılsa da basit bir filtreden farklı çalışmamaktadır. Bu yapı en-iyileme işlemini de kendi içinde barındırdığı ve hızlı çözüme ulaştırdığı için hesap gücü açısından oldukça kullanılabilir bir duruma gelmektedir. Fakat şu ana kadar gerçekleştirilen yazınlar ve kişisel tespitlere göre hücrenel sinir ağları Markov rastgele alanları kadar doğru sonuçlara ulaşmamaktadır.

Bu çalışmada Markov Rastgele Alanları ve Hiresel Yapay Sinir Ağları (MRA-HYSA) model yapısı ile; Markov rastgele alanları ile elde edilen sonuçların RPLA öğrenme algoritması ile eğitilerek giriş (orjinal) görüntüsüne daha yakın sonuçlar elde etmek için çalışılmıştır. MRA-HYSA test sonuçlarına bakıldığında HYSA'nın burada boşluk doldurma işlevini üstlendiği görülmektedir. Markov rastgele alan ile gürültüsü temizlenen ve kenarları belirlenen görüntünün HYSA ile boşluklarının doldurulup giriş görüntüsüne daha yakın sonuçlar elde edilmiştir.

Gelecekte bu birleşik yapı üzerinde daha da çalışılarak hesap süresinin kısaltılıp gerçek zamanlı uygulamalar için uygun hale getirilmeye çalışılacaktır. Ayrıca bu yapı ile biyomedikal uygulamaların yanı sıra jeofizik uygulamaları üzerinde gerçekleştirilmesi sağlanacaktır.



KAYNAKLAR

- [1] CHELLEPPA R., CHATTERJEE S., BAGDAZIAN R., 1985, "Textures Synthesis and Compressing Using Gaussian Markov Random Field Models", IEEE Trans. On SMC, cilt 33, sayfa 298-303.
- [2] CROSS G.R., JAIN A.K., 1983, "Markov Random Field Texture Models", IEEE Trans. On PAMI, cilt 5, sayfa 25-39.
- [3] CHELLEPPA R., CHATTERJEE S., 1985, "Classification of textured using Gaussian-Markov Random Fields", IEEE Trans. On ASSP, cilt 33.
- [4] BESAG J., 1986, "On the statistical analysis of dirty pictures", J.R. Stat. Soc. 48, sayfa 259-302.
- [5] BESAG J., 1974, "Spatial Interaction and the Statistical Analysis of Lattice Systems", J.R. Statist. Soc. B., cilt 36, sayfa 192-236.
- [6] ENSARI T., KILIÇ N., UÇAN O.N., ve ÖZMEN A., 2003, "Markov Rastgele Alanları ve Hücreyel Yapay Sinir Ağları ile Biyomedikal Görüntü İşleme", IEEE SİU 2003 11. Sinyal İşleme ve Uygulamaları Kurultayı, sayfa 609-611.
- [7] GEMAN S., GEMAN D., 1984, "Stochastic relaxation, Gibbs distribution and the Bayesian restoration of images", IEEE Trans. Pattern Anal. Mach. Intelligence, cilt6, sayfa 721-741.
- [8] COHEN F.S., COOPER D.B., 1983, "Real time textured image segmentation based on noncausal markovian random field models", Proc, SPIE Conf. Intell, Robots., Cambridge. M.A.
- [9] DERIN H., COLE W.S., 1986, "Segmentation of textured images using Gibbs random fields", Comput. Vision, Graphics, Image Processing, cilt 35, sayfa 72-98.
- [10] DERIN H., ELLIOT H., KUANG J., 1985, "A new approach to parameter estimation for Gibbs random fields", Proc. IEEE 1985 conf. ASSP, Tampa, FL, sayfa 24.8.1-24.8.4.

- [11] DERIN H., ELLIOT H., SOUCY R., KUANG J., 1985, "Segmentation of SAR imagery using Gibbs distribution models", Proc. Eleventh Int Symp. Machine Processing of Remotely Sensed Data, sayfa 282-295.
- [12] DERIN H., KELLY., P.A., 1989, "Discrete-Index Markov Typed Random Process", Proc. IEEE, cilt 77, sayfa 1485-1509.
- [13] WESZKA J., DYER C.R., ROSENFELD A., 1976, "A Comparative Study of Texture Measures for Terrian Classification", IEEE Trans. On SMC, cilt 6, sayfa 269-285
- [14] FAGERES O.D., PRATT W.K., 1980, "Decorrelation Methods of Texture Feature Extraction", IEEE Trans. On PAMI, cilt 2, sayfa 323-332
- [15] TAMURA H., MORI S., YAMAWAKI T., 1978, "Textural Features Corresponding to Visual Perception", IEEE Tran. On SMC, cilt 8, sayfa 460-470.
- [16] DERIN H., ELLIOT H., CRISTI R., GEMAN D., 1984, "Bayes Smoothing Algorithms for Segmentation of Binary Image Modeled by Markov Random Fields", IEEE Trans. On PAMI, cilt 6, sayfa 707-720.
- [17] DERIN H., ELLIOT H., 1987, "Modeling and Segmentation of noisy and textured images using Gibbs Random Fields", IEEE Trans. Pattern Anal. Mach. Intelligence, cilt 9, sayfa 39-55.
- [18] KILIÇ N., UÇAN O.N., 2003, "Image Segmentation with Markov Random Fields", MBGAK'03 Mühendislik Bilimleri Genç Araştırmacılar Kongresi, sayfa 13-16
- [19] SIMON H., 1999, "Neural Networks", A Comprehensive Foundation Second Edition, Printice-Hall Inc., New Jersey.
- [20] SAĞIROĞLU M.Ş., Mayıs 2001, "Rastgele Markov Alanları ve Hücreli Sinir Ağları ile Görüntü İşleme", Yüksek Lisans Tezi, İ.Ü. Fen Bilimleri Enstitüsü, İstanbul.
- [21] ÖZMETELER E., Ağustos 1989, "Yapay Nöral Ağlar", Yüksek Lisans Tezi, İTÜ Fen Bilimleri Enstitüsü, İstanbul.

- [22] GÜZELİŞ C., 1997, “Yapay Sinir Ağları Ders Notu”, İTÜ, İstanbul.
- [23] GÜZELİŞ C., KARAMAHMUT S., 1994 “Recurrent Perceptron Learning Algorithm for Completely Stable Cellular Neural Networks”, IEE International Workshop on Cellular Neural Networks and Their Applications, Roma, sayfa 321-336.
- [24] ENSARİ T., Haziran 2003, “Hücreyel Yapay Sinir Ağları Uygulamaları”, Yüksek Lisans Tezi, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.
- [25] CHUA L.O., YANG L., Ekim 1988, “Cellular Neural Networks: Theory”, IEEE Transactions on Circuits and Systems, Vol. 35, No. 10, sayfa 1257-1272.
- [26] CHUA L.O., YANG L., Ekim 1988, “Cellular Neural Networks: Applications”, IEEE Transaction on Circuit and Systems, Vol. 35, No. 10, sayfa 1273-1290.
- [27] SUZUKI H., MATSUMOTO T., CHUA L.O., 1992, “A CNN Handwritten Charecter Recognizer”, International Journal of Circuit Theory and Applications”, Vpl. 20, pp. 601-612.
- [28] MATSUMOTO T., CHUA L.O., YOKOHAMA T., Mayıs 1990, “Image Thinning with a Cellular Neural Network”, IEEE Transaction on Circuit and Systems, Vol. 37, No.5, sayfa 638-640.
- [29] SZIRANYI T., CSAPODI M., Kasım 1994, “Texture Classification and Segmentation by Cellular Neural Network using Genetic Learning”, Research Report, Computer and Automation Institue Hungarian Academy of Sciences, Budepest.
- [30] SLOT K., 1992, “Cellular Neural Network Design for Solving Spesific Image Processing Problems”, International Journal of Circuit Theory and Applications, Vol. 20, pp. 629-637.
- [31] SCHULTZ A., et.al., Nisan 1998, “Spatio Temporal CNN for ObjectSegmentation and Object Recognition”, Fifth IEEE International Workshop on Cellular Neural Networks and Their Application Proceedings”, South Bank University, London.

[32] MATSUMOTO T., CHUA L.O., SUZUKI H., Mayıs 1990, "CNN Cloning Template: Connected Component Detector", IEEE Transactions on Circuits and Systems, Vol. 37 No. 5, sayfa 633-635.

[33] MATSUMOTO T., CHUA L.O., SUZUKI H., Ağustos 1990, "CNN Cloning Template: Shadow Detector", IEEE Transactions on Circuits and Systems, Vol. 37 No. 8, sayfa 1070-1073.

[34] ROSKA T., et.al., 1992, "Detecting Moving and Standing Objects using Cellular Neural Networks", International Journal of Circuit Theory and Applications, Vol. 20, pp. 613-628.

[35] SHI B.E., ROSKA T., CHUA L.O., Mayıs 1993, "Design of Cellular Neural Networks for Motion Sensitive Filtering" IEEE Transactions on Circuits and Systems-II: Anolag and Digital Signal Processing, Vol. 40, No. 5, sayfa 320-331.

[36] ZOU F., NOSSEK J.A., Haziran 1991, "Stability of Cellular Neural Networks with Opposite-Sign Templates", IEEE Transactions on Circuits and Systems, Vol. 38, No. 6, sayfa 675-677.

[37] SAVACI F.A., VANDERWALLE J., Mart 1993, "On the Stability of Neural Networks", IEEE Transactions on Circuits and Systems, Vol. 40, No. 3, sayfa 213-215

[38] PAPPAS T., 1992, "An Adaptive Clustering Algorithm for Image Segmentation", IEEE Trans. Signal Process, cilt 40, sayfa 901-914.

ÖZGEÇMİŞ

Niyazi KILIÇ 1978 yılında Bolu'da doğdu. İlk, orta ve lise tahsilini Kocaeli ilinin Gebze ilçesinde tamamladı. 1995 yılında Gebze Sarısu Lisesinden mezun oldu ve yine aynı yıl İstanbul Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Bölümü'nde lisans öğrenimine başladı. 1999 yılında bu bölümden mezun oldu ve yine aynı yıl yüksek lisans eğitimine başladı. Halen İstanbul Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Bölümü'nde Araştırma Görevlisi olarak çalışmaktadır.

