

T.C
MİMAR SİNAN GÜZEL SANATLAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ÇOK KATMANLI KISITLI BOLTZMANN MAKİNELERİ İLE SAYISAL
GÖRÜNTÜLERDEN SANATÇI TANIMA**

YÜKSEK LİSANS TEZİ
Bilgisayar Mühendisi Görkem KINIK

Bilgisayar Ortamında Sanat ve Tasarım Anabilim Dalı
Bilgisayar Ortamında Sanat ve Tasarım Lisansüstü Programı

Tez Danışmanı: Prof. Dr. Salih OFLUOĞLU

MAYIS 2010

**T.C
MİMAR SİNAN FINE ARTS UNIVERSITY
INSTITUTE OF SCIENCE AND TECHNOLOGY**

**RECOGNIZING ARTIST FROM DIGITAL IMAGES BY MULTILAYERED
RESTRICTED BOLTZMANN MACHINES**

**M.SC. THESIS
Computer Engineer Görkem KINIK**

**Division of Computer-Aided Art and Design
Computer-Aided Art and Design Program**

Supervisor: Prof. Dr. Salih OFLUOĞLU

MAY 2010

Görkem KINIK tarafından hazırlanan ÇOK KATMANLI KISITLI BOLTZMANN MAKİNELERİ İLE SAYISAL GÖRÜNTÜLERDEN SANATÇI TANIMA adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.



Prof. Dr. Salih OFLUOĞLU

Tez Yöneticisi

Bu çalışma, jürimiz tarafından Bilgisayar Ortamında Sanat ve Tasarım Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan: : Prof. Dr. Salih OFLUOĞLU



Üye : Yrd. Doç. Dr. Seher BAŞLIK



Üye : Yrd. Doç. Dr. A. Erdem ERBAŞ



Üye : _____

Üye : _____

Bu tez, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygundur.

İÇİNDEKİLER

ÖZET.....	3
ABSTRACT.....	4
ÖNSÖZ	5
ŞEKİL LİSTESİ.....	6
1 GİRİŞ	7
1.1 BİÇİM VE DOKUDAN GÖRÜNTÜ, SANATÇI TANIMA VE ANLAMLANDIRMA	11
1.1.1 Farklı Kadrajlandırmanın Görüntüye Etkileri.....	12
1.1.2 Işık Ve Işık Gürültüsü	13
1.1.3 Bozulma Ve Eserlerin Durumu.....	13
1.1.4 Sıkıştırma, Boyutlandırma Ve Görüntü Filtreleri	13
1.2 ÇALIŞMANIN ÖNEMİ.....	14
1.3 TEZ ÇALIŞMASININ KAPSAMI.....	15
1.4 ARAŞTIRMA YÖNTEMİ	16
2 YAPAY SİNİR AĞLARI	17
2.1 YAPAY ZEKÂ KAVRAMININ VE YAPAY SİNİR AĞLARININ GELİŞİMİ	18
2.2 BİYOLOJİK SİNİR AĞLARI VE YAPAY SİNİR AĞLARI.....	21
2.3 YAPAY SİNİR AĞI MİMARİLERİ	23
2.4 YAPAY SİNİR AĞLARINDA ÖĞRENME	24
2.4.1 Hebbian Öğrenmesi ve Hebb İlkesi	24
2.4.2 Perseptron Öğrenme Kuralı.....	25
2.4.3 Geri Yayılım Öğrenmesi	26
2.5 YAPAY SİNİR AĞLARINDA EĞİTİM VE TEST	27
2.5.1 Nöron Sayısının Seçimi	28
2.5.2 İlk Ağırlıkların Seçimi	28
2.5.3 Öğrenme Katsayısının Seçimi.....	29
3 YAPAY SİNİR AĞLARINDA OLASILIKSAL YAKLAŞIMLAR VE BOLTZMANN MAKİNELERİ.....	30
3.1 REKÜRSİF AĞLAR.....	30
3.2 OLASILIKSAL (STOCHASTIC) SİNİR AĞLARI	32
3.3 BOLTZMAN MAKİNELERİ.....	33

3.4	BOLTZMANN MAKİNELERİNİN OLASILIKSAL DİNAMİKLERİ	33
3.5	BENZETİLMİŞ TAVLAMA (SIMULATED ANNEALING) METODU	35
3.6	KISITLI VE DURUMSAL BOLTZMANN MAKİNELERİ	37
3.6.1	Kısıtlı Boltzmann Makineleri.....	37
3.6.2	Karşılaştırmalı Iraksama (Contrastive Divergence) Eğitim Metodu ...	39
3.6.3	Derin Öğrenme Ağları (Deep Belief Networks)	39
3.6.4	Durumsal Kısıtlı Boltzmann Makineleri (Conditional Restricted Boltzmann Machines)	40
4	PROTOTİP UYGULAMA	42
4.1	GELİŞTİRME ORTAMI	42
4.2	KISITLI VE DURUMSAL BOLTZMANN MAKİNELERİ ALGORİTMALARININ UYGULAMASI	42
4.3	PROTOTİP SİSTEMİN SÜREÇLERİ VE UYGULAMA	45
4.3.1	Ön Filtreleme	45
4.3.2	Eğitim Süreci ve Eğitim Kümelerinin Hazırlanması	47
4.3.3	Ressamları Tanıma.....	49
4.3.4	Programın Kullanımı ve Arayüz	50
4.3.5	Yapay Sinir Ağı Katmanları, Parametreler ve Eğitim	50
4.3.6	Giriş ve Analiz	53
4.3.7	Analiz Sonuçları.....	54
4.4	MAKİNANIN EĞİTİMİ VE İŞLEM SONUÇLARI	55
4.4.1	Eğitim ve Eğitim Kümesi.....	55
4.4.2	Deney Kümesi.....	55
4.4.3	Deney Sonuçları ve Başarım Yorumu.....	57
4.5	SONRAKİ ADIMLAR.....	59
5	SONUÇ	61
	KAYNAKLAR	66
	EKLER.....	69
	Ek 1 : Prototip Uygulama Eğitim Verisi Görüntüleri	69
	Ek 2 : Prototip Uygulama Deney Verisi ve Deney Sonuçları	76

**ÇOK KATMANLI KISITLI BOLTZMANN MAKİNELERİ İLE SAYISAL
GÖRÜNTÜLERDEN SANATÇI TANIMA**

YÜKSEK LİSANS TEZİ
Bilgisayar Mühendisi Görkem KINIK

MİMAR SİNAN GÜZEL SANATLAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MAYIS 2010

ÖZET

Bilgisayar sistemleri ile görüntü tanıma ve anlamlandırma, literatürde üzerine değişik araştırmalar olan popüler bir araştırma konusudur. Robotların hareket ve buna bağlı karar destek mekanizmalarında, şekil tanıma, el yazısı tanıma, ses ve parmak izi tanıma gibi pek çok farklı uygulamalarda yapay zekâ sistemleri ve yapay sinir ağları karşımıza çıkmaktadır.

Bu çalışmada incelenen ve bilgisayar sistemlerinden anlamlandırması beklenen, yüksek gürültü bileşenleri içeren sayısal görüntülerden, bu sayısal görüntünün, bir resim eserinin görüntüsü ise belirli bir küme içerisinde hangi ressama daha çok benzerlik gösterdiğini tespit etmesidir. Çalışma kapsamında Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machine) ve Durumsal Kısıtlı Boltzmann Makineleri (Conditional Restricted Boltzmann Machine) yapay sinir ağı algoritmaları ile görüntüleri işleyecek bir prototip geliştirilmiş ve bilgisayar sisteminin gösterdiği başarı incelenmiştir.

Prototip uygulama Vincent Van Gogh, Salvador Dali ve Pablo Picasso ya ait İnternet üzerinden elde edilen düşük çözünürlüklü bir eğitim kümesi ile eğitilmiştir. Prototip uygulamanın bu eğitim kümesinde bulunmayan veya yapısal farklılıklar gösteren (kadraj farkı, sıkıştırma farkı, çözünürlük farkı ve benzer sayısal sinyal gürültüleri) düşük çözünürlüklü yüksek gürültü bileşenleri içeren görüntüler ile testi sonucu sanatçıları tanımada %60'ın üzerinde başarı elde ettiği görülmüştür.

Tez Yöneticisi : Prof. Dr. Salih OFLUOĞLU

Anahtar Kelimeler : Sayısal görüntü işleme, Restricted Boltzmann Machines, Conditional Restricted Boltzmann Machines, Sayısal Görüntülerden Ressam Tanıma, Yapay Zekâ, Yapay Sinir Ağları, Yapay Zekâ ve Sanat

RECOGNIZING ARTISTS FROM DIGITAL IMAGES BY MULTILAYERED RESTRICTED BOLTZMANN MACHINES

M.SC. THESIS
Computer Engineer Görkem KINIK

MİMAR SİNAN FINE ARTS UNIVERSITY
INSTITUTE OF SCIENCE AND TECHNOLOGY
MAY 2010

ABSTRACT

Image recognition with computer systems is a popular research topic on which there are many research projects. Artificial intelligence systems and artificial neural networks are encountered in a variety of applications like robot decision support systems for movements, symbol recognition, handwriting recognition, voice recognition and fingerprint recognition.

In this research, an artificial intelligence system, based on neural networks, is challenged to identify relational probabilities of an image belonging to an artist from a set of artists, using digital images of paintings with high noise components. In the scope of the research, Restricted Boltzmann Machines and Conditional Restricted Boltzmann Machines algorithms are applied in a prototype software and its success is tested.

The prototype software is trained with a set of low resolution images from the internet belonging to paintings of Vincent Van Gogh, Salvador Dali and Pablo Picasso. It was observed that the prototype software achieves success rates above %60 on recognizing artists when tested with images which are very different in content or structurally different (frame, canvas size, resolution, compression) from the images in the training set.

Supervisor : Prof. Dr. Salih OFLUOĞLU

Keywords : Digital Image Processing, Restricted Boltzmann Machines, Conditional Restricted Boltzmann Machines, Recognition of Artists from Digital Images, Artificial Intelligence, Artificial Neural Networks, Artificial Intelligence and Art

ÖNSÖZ

Çalışmam süresince bana yol gösteren, desteğini, bilgisini, fikirlerini ve zamanını esirgemeyen değerli hocam Prof. Dr. Salih OFLUOĞLU'na,

Yazılım ile ilgili fikirlerini, çalışmama yardımlarını, yüksek lisans eğitimimi ve bu tez çalışmasını tamamlamam için bana verdiği cesareti, desteği ve gösterdiği sabrı asla unutmayacağım Bilgisayar ve Endüstri Mühendisi Bahar YELKEN'e,

Çalışmam ve eğitim hayatım boyunca destekleri ve dostlukları ile hep yanımda olan arkadaşlarım Çevre Mühendisi Canburak ÖZKAL ve Kontrol Mühendisi Yaver KAMER'e,

Sinir hücreleri ile beni ilk tanıştıran, öğreten ve yapay sinir ağlarına ilgi duymamı sağlayan sevgili anneannem, Biyoloji Öğretmeni Aynur BAŞARAN'a

Ve eğitim hayatım boyunca beni hep destekleyen değerli aileme, sonsuz teşekkür ve şükranlarımı sunarım.

Görkem KINIK

Mayıs 2010

ŞEKİL LİSTESİ

Şekil 1.1 flickr.com İnternet sitesinden resimler ve kullanıcı etiketleri. (a) dahlia, altın, kapı, park, çiçek, sis; (b) telefon kamerası, hayvan, köpek	9
Şekil 1.2 ALIPR projesinin çevrimiçi uygulamasının, Dali'nin bir eseri için yaptığı yorum.	10
Şekil 1.3 Picasso'nun farklı dönemlerinden eserleri; Rüya 1932 ve Yaşlı Gitarist 1903.....	12
Şekil 2.1 Memeli Sinir Hücresi Yapısı	21
Şekil 2.2 Yapay sinir hücresi ve çok katmanlı yapay sinir ağı	22
Şekil 2.3 Sırasıyla, doğru eğitilmiş sinir ağı sınıflandırması ve aşırı eğitilmiş sinir ağı sınıflandırması.....	28
Şekil 3.1 Rekürsif bir ağ modeli	30
Şekil 3.2 Boltzmann Makinesi Grafi.....	31
Şekil 3.3 Hopfield Ağı Grafi.....	32
Şekil 3.4 Benzetlenmiş tavlama metodu ile hata fonksiyonunun minimizasyonu	36
Şekil 3.5 Temsili Kısıtlı Boltzmann Makinesi Grafi	37
Şekil 3.6 Kısıtlı ve Durumsal Boltzmann Makinelerinin Katman Yapıları.....	41
Şekil 4.1 Prototip uygulamada Kısıtlı ve Durumsal Boltzmann Makinelerinin birleştirilmesi	43
Şekil 4.2 Sistemden beklenen çıkış verisi yapısı	45
Şekil 4.3 Hinton ve Teh'in yüz tanıma için yaptıkları önfiltreleme. a) Orijinal görüntü, b)Gözlerin belirlenmesi, c) Gözlere göre çevirme işlemi, d)Kırpma işlemi, e) Arka plan temizleme, f) Yoğunluk histogramı dengeleme	46
Şekil 4.4 Sanatçıları tanıma işlemi sırasında uygulamanın akışı	49
Şekil 4.5 Prototip Uygulamanın Kullanıcı Arayüzü	50
Şekil 4.6 Prototip Uygulama Birinci Katman Ayarları Arayüzü	51
Şekil 4.7 Prototip Uygulama İkinci Katman Ayarları Arayüzü.....	53
Şekil 4.8 Prototip Uygulama Veri Giriş ve Birinci Katman Sonuç Arayüzü.....	54
Şekil 4.9 Prototip Uygulama Analiz Sonuçları Arayüzü	55
Şekil 4.10 Picasso deney örneği.....	56
Şekil 4.11 Van Gogh deney örneği	57
Şekil 4.12 Van Gogh deney örneği	57
Şekil 4.13 Picasso deney örneği.....	58
Şekil 4.14 Dali deney örneği.....	58

1 GİRİŞ

Psikoloji biliminin ortaya çıkması ve gelişmesi ile insanoğlu, zekâ, yaratıcılık, algı ve benzeri kavramları tanımlara yerleştirmeye çalışmıştır. Günümüz teknolojisinde bu tanımlar, yakın geçmişte günlük yaşamın bir parçası olmayı başarmış ve hızla gelişen, performans ve kapasitede sınır tanımayan bilgisayar sistemlerinin yeteneklerini, bir üst seviyeye çıkarmalarının önündeki önemli engellerden biri olarak görülmektedir. Çünkü bilgisayar sistemleri, karşılaştığımız pek çok problemde bir operatör yardımı olmadan karar verememektedirler.

Bu kapsamda hem bilişim dünyasında hem de akademik çevrelerde kapsamlı çalışmalar yürütülmektedir. Mantiğa dayalı rasyonel psikoloji anlayışının gelişmesi, canlı davranışın bilgisayar sistemleri ile modellenenabilir olabileceği kuşkusunu yaratmış, yapay zekâ alanındaki araştırma ve projelere hız kazandırmıştır (Doyle, 1983)¹. 1990'lı yıllardan itibaren makinelerin düşünebileceği ihtimali bilimkurgu olmaktan çıkmış ve bilim çevrelerinde ilgi görmeye başlamıştır.

Otonom sistemleri yanlış yapabilecek kadar yaratıcı ve zeki hale getirmeyi amaçlayan bu çalışmaların önemli odak noktalarında biri de anlama ve algılama olmuştur. Psikoloji, felsefe, nöroloji, dil bilimleri, antropoloji ve sosyoloji gibi bilimlerde temel bir kavram olan algı, bilgisayar bilimleri alanında yapılan yapay zekâ çalışmalarında da önemli bir araştırma konusu haline gelmiştir. İnsan zekâsının dinamiklerini matematiksel olarak modelleyip taklit etmeyi hedefleyen yapay zekâ uygulamalarının önündeki temel bilinmezlerden biri insan algısıdır.

Burada yapay zekâ ve algı modellemesi ile hedeflenen iki önemli amaç vardır. Birincisi motorları ve makineleri insan gücü yerine kullandığımız gibi makine zekâsını, insan zekâsı yerine kullanmaktır. İkinci ve bu çalışmanın kapsamında incelenecek olan amaç ise makine üzerinde oluşturulan modeller ile insan algısının ve zekâsının bilinmezlerini ortaya çıkartmaktır. (Simon, 1994)²

Yapay zekâ ile ilgili önemli araştırma konularından birisi ise görsel algılamadır. Günümüzde hareketli, sabit, renkli, renksiz vb. pek çok farklı tipte görüntüyü işleyip,

¹ Doyle, J. (1983). What is Rational Psychology? Toward a Modern Mental Philosophy. AI Magazine 4(3) , 50-53.

² Simon, H. (1994). Omni Magazine, Interview with Herbert Simon. (D. Stewart, Röportajı Yapan)

anlamlandırılan ve bu anlamlara göre kararlar verebilen yapay zekâ uygulamaları bulunmaktadır. İnsan görüntü algısı üzerinde yapılan bazı çalışmalar, görüntü algısını, basit geometrik biçimlerden başlayan ve tanımlanabilecek veya benzetilebilecek objeler arasında, farklı benzerlik ağırlıkları ile bağdaştırılmış, büyük bir ağaca benzetmektedir (Biederman, 1987)³. Yapay zekâ uygulamalarının pek çoğunda da bu genel anlayış benimsenmiştir.

Görüntü algılama konusunda geliştirilmiş çok sayıda yapay zekâ uygulaması bulunmaktadır. Bunlardan bazıları:

- Kameralar aracılığı ile çevresel görüntüleri değerlendirip, objeleri ve mekânı tanıyan belirli görevleri tamamlayabilen robotlar (Meger, et al.)⁴
- Uydu fotoğrafları ile arazi şekillerini ve coğrafi özellikleri belirleyebilen yazılımlar (Kargel & Brandt, 1993)⁵
- Etkileşimli drama (Project Façade, Expressive AI), yaratıcı olasılıksal sistemler ve doku modelleme sistemleri (Mateas, 2002)⁶ (Heingartner & Douglas, 2004)⁷
- El yazısı, insan yüzü, parmak izi ve araç plakası görüntüleri gibi örüntüleri tanımlayabilen sistemler
- Taranmış dokümanları ve görüntüleri semantik yapılarda sınıflandıran sistemler (Berardi, Lapi, & Malerba, 2004)⁸
- Etkileşimli donanımlar yardımı ile kullanıcı eğitmenliğinde objeleri ve çevreyi tanıyabilen sistemler
- İnternet üzerindeki veya kullanıcıların yüklediği fotoğraf ve görüntüleri kelimeler ile etiketleyebilen sistemler (ALIPR Project) (Wang & Li, Real-Time Computerized Annotation of Pictures, 2008)⁹ (Wang, Li, & Wiederhold, SIMPLiCity: Semantics-sensitive integrated matching for picture libraries, 2001)¹⁰

³ Biederman, I. (1987). Recognition By Components: A Theory of Human Image Understanding. *Psychological Review* Vol. 94, No. 2 , 115-147.

⁴ Meger, D., Forssen, P.-E., Lai, K., Hemler, S., McCann, S., Southey, T., et al. *Curious George, An Attentive Semantic Robot*. Vancouver: Department of Computer Science, University of British Columbia.

⁵ Kargel, D., & Brandt, W. (1993). *Image Understanding Using Artificial Intelligence Technology*. AAAI Technical Report WS-93-04.

⁶ Mateas, M. (2002). *Interactive Drama, Art and Artificial Intelligence*. Pittsburgh: Computer Science Department, Carnegie Mellon University.

⁷ Heingartner, & Douglas. (2004, June 13). *A Computer That Has An Eye for Van Gogh*. *The New York Times*.

⁸ Berardi, M., Lapi, M., & Malerba, D. (2004). *An Integrated Approach for Automatic Semantic Structure Extraction in Document Images*. Bari: Dipartimento di Informatica.

⁹ Wang, J. Z., Li, J., & Wiederhold, G. (2001). *SIMPLiCity: Semantics-sensitive integrated matching for picture libraries*. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, vol. 23, no. 9 , 947-963.


¹⁰ Wang, J. Z., & Li, J. (2008). *Real-Time Computerized Annotation of Pictures*. *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE*

- Resimlerin orijinalliğini ve yapıtların ressamlar ile aralarındaki matematiksel ilişkilerini denetleyebilen, eserlerin orijinalliği üzerinde yorum yapabilen uzman sistemler (AUTHENTIC PROJECT) (H. J. van den Herik, 1999)¹¹

Bu çalışmalardan ALIPR (Automatic Linguistic Indexing of Pictures - Real Time) projesi, bu tez çalışması kapsamında geliştirilen prototip uygulamadan tamamen farklı yöntemler kullanılarak geliştirilmiş olmasına rağmen uygulamanın başarısı, konu itibarıyla bu tez çalışmasına benzerliği, istatistiksel öğrenme ve sınıflandırma yöntemlerini kullanması ile ön plana çıkmaktadır. ALIPR projesinde Jia Li ve James Wang, yüksek performans ile gerçek zamanlı çalışan ve sayısal görüntüleri sınıflandıran bir yapay zekâ uygulaması geliştirmişlerdir. Bu uygulamada sayısal görüntüler, sözcük etiketler ile eşleştirilmiştir.



(a)



(b)

Şekil 1.1 flickr.com İnternet sitesinden resimler ve kullanıcı etiketleri.
(a) dahlia, altın, kapı, park, çiçek, sis; (b) telefon kamerası, hayvan, köpek

ALIPR projesi kapsamında geliştirilen uygulama ve eğitim algoritması, flickr.com İnternet sitesindeki sayısal görüntüler ve bu sayısal görüntülere ziyaretçilerinin eklediği konu etiketleri ile eğitilmiştir. Kullanıcı etiketleme işlemi Şekil 1.1'deki gibidir. Proje kapsamında yapılan deneylerde, sistemin tek işlemcili bir bilgisayarla bile gerçek zamanlı ve tutarlı etiketler ürettiği tespit edilmiştir (Wang & Li, Real-Time Computerized Annotation of Pictures, 2008). Uygulamaya çevrimiçi olarak <http://www.alipr.com> adresinden de ulaşılabilmektedir.

¹¹ H. J. van den Herik, E. O. (1999). The Hand of the Master. An analysis of the Visual Signatures of Painters. R. Timman Foundation.



Top 15 Computer-Predicted Tags
 ALIPR is like a child trying to learn about the world. Please help us to teach ALIPR. Check those correctly annotated words.

man-made texture animal car rock
 lizard natural tree grass sport
 forest herb_spice micro_image bead indoor

Thought of other terms missed by ALIPR? Please add here, separated by commas ','
 and make the picture searchable

Optional information:
 Picture title
 URL to see related pictures
 Copyright (hypertext ok)

Şekil 1.2 ALIPR projesinin çevrimiçi uygulamasının, Dali'nin bir eseri için yaptığı yorum.

Yapay zekâ ve yapay zekâ ile görsel anlamlandırma alanında yapılan bir diğer çalışma da “Curious George” (Meraklı George) robotudur (Meger, et al.). Bu robot uluslararası yapay zekâ yarışmalarında belirlenen standart bir dizi tanımlama ve tanımlamaya göre hareket etme görevini başarı ile tamamlamıştır. 2007 “Association for the Advancement of Artificial Intelligence” konferansında yapılan robot görüntü işleme yarışmasında, bir robotun başarılı olabilmesi için üç adımlı bir görev listesi belirlenmiştir. Birinci adımda robotlar belirli bir hedef kümesi içinde bulunan nesnelerin İnternet üzerinde bulunan fotoğrafları ile yapay zekâ algoritmalarını eğitmektedirler. İkinci adımda ise robotlar özel olarak oluşturulmuş, hedef nesneler ve hedef olmayan nesneler ile döşenmiş bir odada dolaşmakta ve odayı incelemektedirler. Üçüncü adımda ise robotların hedef nesnelerin oda içerisindeki yerlerini ve nesneleri tanımlaması beklenmektedir. Robotların performansı, robotların ürettiği nesne tanımlamaları ile insanların nesne tanımlamaları karşılaştırılarak ölçülmüştür. “Meraklı George” robotu bu yarışmada birinci olarak, yapay zekânın insanlar gibi, sadece önceden resmini gördükleri nesneleri tanıyabildiğini göstermiştir.

İnsanlar ve diğer birçok memeli canlının biyolojik sinir ağları ile farkında olmadan çözdüğü ancak bilgisayar sistemlerinde bilinen algoritmalar ile çözülmesi mümkün olmayan bir başka problem ise insan yüzü tanımadır. Her insan yüzü birbiri ile benzer şekilsel kompozisyona sahip fakat detaylarında birbirinden tamamen farklı karakteristik özellikler göstermektedir. Yüz tanıma konusu üzerinde pek çok yapay zekâ uygulaması geliştirilmiş ve geliştirilmekte, sistemlerin başarısı da günden güne artmaktadır. Bu tez çalışması kapsamında da önerilen ve geliştirilen prototip uygulamadaki yapay zekâ bileşenini oluşturan Kısıtlı Boltzmann Makineleri algoritması da, bu algoritmanın mimarlarından biri olan Geoffrey Hinton'un araştırmalarından birinde (Teh & Hinton, 2000), yüz tanıma için kullanılmış ve başarılı sonuçlar elde edilmiştir. “Rate-coded Restricted Boltzmann Machines for Face Recognition” adlı makalede Hinton ve Teh, biyolojik sinir ağlarından esinlenmiş ve her bireye ait yüz görüntüleri ile eğitilen ve daha sonra bir test görüntüsünü öğrenilen yüzler ile karşılaştırıp yüzün kime ait olduğunu tespit

edebilen bir sistem tanımlamışlardır. Bu sistemin, yapılan benzer çalışmalara göre temel farkı öğrendiği yüzleri bir veritabanında değil sinir ağının hücresel sisteminde olasılıksal olarak modelliyor olmasıdır. Ayrıca bu tez çalışmasında da olduğu gibi yüz tanımada da ışık ve kompozisyon gürültüsünden kaynaklı problemler çözülmüştür. Işık ve kompozisyonun görüntü anlamlandırma ve tanıma sistemlerinde yarattığı zorluklardan ilerleyen bölümlerde bahsedilecektir.

Bütün bu çalışmalar yapay zekâ sistemlerinin görüntü algılamadaki gelişimini ve potansiyelini ortaya koymaktadır.

Bu tez çalışmasında incelenecek olan konu ise, belirli bir yapay zekâ algoritmasının, doku ve biçimden bağımsız olarak, bir görüntüye ressamın kattığı yorumu algılamadaki başarısının ortaya koyulmasıdır. Konusunda uzman veya çalışmanın incelediği ressamı biraz olsun tanıyan bir insan için, bu ressamın eserlerinin görüntülerinden yola çıkarak, görüntünün hangi ressamın resmine ait olabileceğini tahmin etmek nispeten kolaydır. Ancak bir makinenin, herhangi bir görüntüden, bu görüntünün hangi ressama ait çizgileri bulduğunu anlamasının önünde pek çok zorluk bulunmaktadır. Karşılaşılan bu zorluklar, ilerleyen bölümlerde incelenecektir.

1.1 BİÇİM VE DOKUDAN GÖRÜNTÜ, SANATÇI TANIMA VE ANLAMLANDIRMA

Görüntü algılama üzerine yapılan pek çok yapay zekâ araştırmasında ve uygulamasında sistemlerin şekilleri, yazıları, biçimleri tanınması, yüksek başarı oranları ile gerçekleştirilmiştir. Ancak farklı sanatçılara ait benzer kompozisyonları ayırt etmek gelişmiş bir yapay zekâ sistemi için bile çok zordur. Örneğin sistemin resimlerin sadece portre veya natüremort olup olmadığını anlaması, bir resmin hangi sanatçının elinden çıktığını anlamasına göre daha kolaydır.

Ayrıca sanatçılar farklı dönemlerinde çok farklı eserler üretebilmektedirler. Biçim ve kompozisyon olarak tamamen farklı olabilen bu eserlerin, bilgisayar tarafından aynı sanatçıya ait olarak sınıflandırılabilmesi için, eğitim kümesi olabildiğince geniş tutulmalıdır. Şekil 1.3’de Picasso’nun farklı dönemlerine ait eserlerinin oldukça farklı olduğu görülmektedir.



Şekil 1.3 Picasso'nun farklı dönemlerinden eserleri; Rüya 1932 ve Yaşlı Gitarist 1903

Tanıma kümesindeki sanatçı sayısı arttırıldıkça problem sayısal olarak daha da karmaşık hale gelmektedir. Sınıflandırma kümesindeki tüm sanatçıların, farklı dönemlerinde ürettiği farklı eserleri ile eğitilse bile bir bilgisayar programı için daha önce eğitim veri kümesinden bulunmayan ve gürültü bileşenleri içeren bir görüntüden, görüntüde bulunan resme ait verileri seçerek sanatçıyı tahmin edebilmesi, son derece karmaşık bir yapay zekâ problemidir.

1.1.1 Farklı Kadrajlandırmanın Görüntüye Etkileri

Resim, ölçeği, boyutları ve açıları farklı kadrajlarla fotoğraflandırılabilir. Güvenilir kaynaklardan edinilmiş bile olsa bir resme ait görüntüyü oluşturmak için kullanılan kadrajın, orijinal verinin ne kadarını kestiği, açısız değerleri, odaklanması ve ölçeklendirilmesi bilinmemektedir. Sistemin, kadrajın veri üzerinde yaratabileceği değişimlerden bağımsız olarak veriden, görüntüyle sanatçıyı eşleştirmesi ve farklı kadrajlandırılmış aynı esere ait görüntüler için bile aynı yorumu yapması oldukça zordur. Aynı eserin aynı fotoğraf makinesiyle ve hatta aynı kadrajla çekilmiş iki fotoğrafı arasında bile sayısal olarak kurallaştırılıp belirlenemeyecek ve görüntüden çıkartılamayacak farklılıklar vardır. Görüntü işlemenin, insan yüzü tanıma alanında yapılan benzer çalışmalarda ve deneylerde, standart veya belirli açısız değerler dahilinde kadrajlar kullanılmaktadır (Chen, Yin, Zhou, Comaniciu, & Huang, 2005)¹².

¹² Chen, T., Yin, W., Zhou, X. S., Comaniciu, D., & Huang, T. S. (2005). Illumination Normalization for Face Recognition and Uneven Background Correction Using Total Variation Based Image

1.1.2 Işık Ve Işık Gürültüsü

Her farklı fotoğrafta resim üzerine düşen ışık ışınlarının açıları, miktarları ve noktasal kaynak sayıları farklı olabilir. Gölge ve ışığın insan algısını bile tamamen değiştirebileceği göz önünde bulundurulduğunda farklı ışıklandırma koşullarında makinenin aynı yorumu yapabilmesi görevini daha da zorlaştırmaktadır (Zhao, Chellappa, Rosenfeld, & Phillips, 2000)¹³. Konuyla ilgili görüntü işleme alanında farklı tanıma algoritmalarıyla birlikte ışık gürültüsünü azaltmak için çeşitli çalışmalar bulunmaktadır. Ancak görmeyi ve görüntülemeyi sağlayan ışığın sebep olduğu gürültüyü ortadan tamamen kaldırmak mümkün değildir. Özellikle insan yüzü tanıma çalışmalarında, ışık gürültüsü üzerine çalışmalar yapılmıştır (Chen, Yin, Zhou, Comaniciu, & Huang, 2005).

1.1.3 Bozulma Ve Eserlerin Durumu

Aynı sanatçıya ait bazı eserler çok iyi korunmuş olmasına karşın her eser için aynı söyleyemez. Bu da sisteme giriş yapılan veri üzerinde ciddi değişikliklere yol açmaktadır. Makine yorumunu yaparken eserlerin bozulma oranlarını da göz ardı etmelidir.

1.1.4 Sıkıştırma, Boyutlandırma Ve Görüntü Filtreleri

Tez çalışmasında geliştirilen prototip uygulama İnternet üzerinden elde ettiği görüntüleri tanımaktadır. Görüntülerin İnternet üzerinden elde edilmesinin sebebi, İnternetin bilgisayar yazılım sistemlerinin kolay ulaşabileceği zengin bir bilgi kaynağı olması ve aynı esere ait çok farklı kalitede görüntüleri barındırmasıdır.

İnternet üzerinden elde edilen bu görüntüler çok farklı boyutlarda olabilirler. Ayrıca ağ üzerinde hızlı transfer edilebilmeleri için genellikle JPEG algoritması başta olmak üzere farklı sıkıştırma algoritmaları ile ardışık olarak defalarca sıkıştırılmış olabilirler. Bu sıkıştırma algoritmaları, resimin fotoğrafına ait verinin üzerinde belirli ölçülerde kayıplara yol açmaktadır. Bu kayıpları azaltmak için fotoğrafçılar tarafından kullanılan uygulamalar bulunmaktadır (Evening)¹⁴. Ancak buna rağmen bu kayıplar tamamen ortadan kaldırılamamaktadır.

Düşük çözünürlüklü ve küçük boyutlu görüntülerde ise zaten insan gözü ile farkın algılanması mümkün olmadığından, sıkıştırma gürültüsü göz ardı edilmektedir. Ancak bilgisayar için farklı algoritmalarla sıkıştırılmış, sıkıştırılmamış veya farklı fotoğraf makineleri ile elde edilmiş görüntüler birbirlerinden sayısal olarak tamamen farklı verilerdir ve makinenin bunların aynı olduğunu tespit etmesi oldukça zor bir görevdir.

Models. University of Illinois at Urbana Champaign, Columbia University, Siemens Corporate Research.

¹³ Zhao, W., Chellappa, R., Rosenfeld, A., & Phillips, P. (2000). Face Recognition: A literature Survey. University Of Maryland.

¹⁴ Evening, M. Adobe Photoshop CS2 for Photographers. ISBN: 0 240 51984 1.

Bunun dışında İnternet üzerinde elde edilen görüntülerde, eser fotoğraflandıktan veya tarandıktan sonra herhangi bir görüntü filtresi uygulanıp uygulanmadığı, renk düzeltmesi yapılıp yapılmadığı veya bir değişiklik yapıldıysa ne yapıldığı ve nasıl parametrelerle bu işlemin gerçekleştirildiği bilinmemektedir. Basit bir renk düzenlemesi yapılmış bir fotoğraf ile yapılmamış olan, gözle fark edilmese bile sayısal olarak büyük ölçüde farklıdır.

Özetle farklı kadrajlar, sıkıştırma algoritmaları, farklı boyutlandırmalar, ışık ve eserlerin farklı korunmuşlukta olması bilgisayarın işleyeceği görüntülerde yüksek miktarda gürültü oluşturmakta ve bu veriler üzerinde konvansiyonel istatistik ve matematiksel metotlar ile çalışmayı imkânsızlaştırmaktadır. Özellikle İnternet üzerinden elde edilen bu tip verilerde daha büyük oranlarda gürültü bulunmaktadır. Gürültü filtreleme bu tez çalışmasının kapsamında değildir. Ancak prototip uygulamada gerçekleştirilen yapay zekâ uygulaması, gürültüyü yüksek oranda göz ardı etmektedir.

1.2 ÇALIŞMANIN ÖNEMİ

Bilgisayar sistemleri tarafından otonom olarak ve etkin bir biçimde, sayısal görüntüleri tanıma, sınıflandırma ve etiketleme uygulamaları akademik çevrelerde, üzerinde yoğun araştırmaların devam ettiği bir konudur. Belirli bir alandaki sayısal görüntüleri doğru ve etkin bir şekilde sınıflandıran bir bilgisayar sistemi, pek çok alanda devrim yaratacaktır. İnternet tabanlı resim arama motorları, çevrimiçi görüntü paylaşım toplulukları, bilimsel araştırmalar, sanat, eğitim, güvenlik gibi pek çok uygulama alanında kullanılabilir bu sistemler halen gelişim aşamasındadırlar.

Yapay zekâ sistemlerinin karmaşık yapısı, bu sistemlerde her zaman belirli ölçüde hatanın var olması, deney ve başarı ölçütlerinin zaman zaman gerçek problemlerden farklı olabilmesi, gelişmiş yapay zekâ sistemlerinin donanımsal gereksinimlerinin yüksek olması bu çalışmaların karşılaştığı bazı zorluklardandır.

Bu çalışmada öne sürülen fikir ise belirli yapay zekâ algoritmaları kullanılarak resimlere ait görüntülerden eserlerin sanatçılarının tahmin edilebileceğidir. Çalışma dahilinde geliştirilen prototip uygulama ile elde edilen sonuçlar bu fikrin gerçekleştirilebileceğini göstermektedir.

Geliştirilen prototip uygulama olasılıksal bir sistemdir ve girilen sayısal görüntüye karşın, görüntünün hangi sanatçı ile ilişkili olabileceğine dair istatistiksel bir çıkış yapmaktadır. Kısa bir sürede ve kısıtlı kaynaklarla geliştirilen prototip uygulamanın, İnternet üzerinden elde edilen, yüksek gürültü bileşenleri içeren görüntüler ile yapılan deneyler sonucu, sanatçıları yaklaşık %65 başarı ile tanıdığı tespit edilmiştir. Başka bir ifade ile prototip sistemin, çevrimiçi arama motorlarından, eğitim kümesinde bulunan sanatçıların isimleri ile yapılan arama sonuçlarından elde edilen 100 adet rastgele resim görüntüsünün, 65 adedini doğru sanatçı ile eşleştirebildiği söylenebilir. Yapılan deneylere ait girişler ve sistemin ürettiği sonuçlara ilerleyen

bölümlerde daha detaylı değinilecektir. Yapılan deneylerin tamamı ve deney kümeleri için sistemin ürettiği sonuçlar, çalışmanın eklerinde bulunmaktadır.

Deney sonuçları ve literatür taraması, sayısal görüntüler üzerinde çalışan, benzer algoritmalar kullanan yazılımlar ile otonom ve etkin bir şekilde, sanatçıların veya eserlerin dönemleriyle ilgili bilgi edinilebileceğinin, eserlerin sahte veya gerçek olup olmadığının anlaşılabilceğinin, zarar görmüş veya büyük kısmı kaybolmuş eserlerin hangi sanatçı, sanatçılara veya dönemlere ait olabileceğinin, farklı sanatçılar arasında benzer özellikler bulunup bulunmadığının anlaşılabilceğinin ve sanatçıların karakteristik özelliklerinin sayısal olarak modellenilebileceğinin mümkün olabileceğini göstermektedir.

Literatürde sanat eserlerini sanatçılar ile eşleştirebilen ve birden fazla sanatçı üzerinde çalışabilen yapay zekâ çalışmaları bulunmamaktadır. Çalışmanın bu anlamda da öncü olması ve yeni bilimsel araştırma konuları ve alanları doğurması beklenmektedir. Disiplinler arası bu çalışma, yapay zekâ kavramı ile sanat arasında köprü kuracak gelecek çalışmaları, teşvik etmeyi de hedeflemektedir.

Prototip uygulamada kullanılan algoritmalar, Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines) ve Durumsal Kısıtlı Boltzmann Makineleri (Conditional Restricted Boltzmann Machines), özellikle sınıflandırma problemleri, kaotik zaman serilerinin ve canlı davranışlarının analizi ile ilgili alanlarda başarıları ölçülmüş algoritmalarıdır. Ancak bu algoritmaların, çalışma kapsamındaki problemi, belirtildiği şekilde çözdüğüne dair herhangi bir çalışma bulunmamaktadır. Bu tez çalışması, Kısıtlı Boltzmann Makineleri ve Durumsal Kısıtlı Boltzmann Makineleri ile görüntülerden sanatçı analizi yapılabileceğini ve konu üzerinde bilimsel araştırmalar ve deneylerin sürdürülebileceğini göstermiştir.

1.3 TEZ ÇALIŞMASININ KAPSAMI

Bu tez çalışması kapsamında, literatür taraması ışığında, Java programlama dili ile Kısıtlı Boltzmann Makineleri ve Durumsal Kısıtlı Boltzmann Makineleri algoritmaları kullanılarak tümleşik bir yapay zekâ prototip uygulaması geliştirilmiş, uygulama Vincent Van Gogh, Pablo Picasso ve Salvador Dali'ye ait resimlerin İnternet üzerinden elde edilen resimlerine ait görüntüleri ile eğitilmiş ve başarısı test edilmiştir. Prototip uygulama kapsamında sistemin farklı parametreler ile eğitimi, testi ve sonuç analizi için gerekli yazılım ara yüzleri geliştirilmiştir. Geliştirilen uygulama, yaklaşık %65 başarı ile kapsamdaki sanatçılara ait resimlerin yüksek gürültü içeren ve belirli bir standardı bulunmayan görüntü veya görüntülerine ait parçalardan, bu görüntülerin hangi sanatçının eserine ait olduğunu tespit etmiştir.

1.4 ARAŐTIRMA YÖNTEMİ

Bu tez alıőmasında literatür taraması ve buna baėlı prototip uygulama geliőtirilmesi yapılmıőtır. Geliőtirilen prototip uygulama üzerinde gerekleőtirilen deneyler ve bu deneylerin sonuçları ile araőtırma soruları yanıtlanmış ve öne sürülen hipotez desteklenmiőtir. alıőmanın kapsamında cevaplanmaya alıőtılan temel araőtırma sorusu, ift katmanlı bir kısıtlı Boltzmann makinesi yapay sinir aėı ile İnternet üzerinden elde edilen ve yüksek gürültü bileőtini ieren sayısal görüntülerin, eėer bir sanatının resmine ait ise, sanatı ile doėru bir Őekilde eőtleőtirilip eőtleőtirilemeyeceėidir.

2 YAPAY SİNİR AĞLARI

Çoğunlukla sinir ağları olarak da adlandırılan yapay sinir ağları biyolojik sinir ağlarının yapısal özelliklerini ve fonksiyonlarını taklit etmeye çalışan matematiksel bilgisayar modelleridir. Birbirleri aralarında bağlantı ağırlığı katsayıları bulunduran yapay nöronlardan oluşmaktadırlar. Yapay sinir ağları çoğunlukla öğrenme sırasında üzerlerinden geçirilen verideki içsel ve dışsal değişim ve eğilimlere göre yapılarını veriye adapte ederler. Modern yapay sinir ağları lineer olmayan istatistiksel veri modelleme araçları olarak da adlandırılabilir. Genellikle işlenen veri kümesindeki karmaşık bağlantı veya örüntüleri modellemek için kullanılırlar.

Akademik çevrelerde yaygın olarak kabul görmüş tam bir tanımı olmasa da, yapay sinir ağları literatürde genellikle, basit yapay sinir hücresi işlemcilerinin katmanlar halinde bir araya getirilmesi, bu yapılar arasında bağlantılar kurulması ve yapay sinir hücreleri parametreleri ile optimizasyonu sonucu karmaşık, toplu veya tekil davranışlar sergileyebilen ağlar olarak tanımlanır.

Yapay sinir ağları, merkezi sinir sistemi ve düşüncenin yapı taşı sinir hücreleri üzerinde yapılan araştırmalardan esinlenilerek tasarlanmışlardır. Bir sinir ağı modeli, yapay sinir hücresi, nöron, yapay nöron veya birim (unit) olarak adlandırılan basit düğümlerin (nodes) birbirlerine bağlanarak oluşturduğu ağdır ve ağ terimi bu bağlantılardan yola çıkılarak oluşmuştur. Bir yapay sinir ağının teoride dış dünya problemlerine adapte olmasına gerek yoktur. Ancak pratik kullanım, ağın istenen çıkış sinyalini üretebilmesi için bağlantı ağırlıklarını (strength of connections) güncelleyen algoritmaları gerektirmektedir.

Yapay sinir ağları, problemler üzerinde, klasik algoritmaların çoğunda olduğu gibi belirli alt görevler üzerinde odaklanmış iş birimleri oluşturularak değil, kolektif ve paralel çalışma yapıları ile biyolojik sinir ağlarına fonksiyonel olarak benzemektedirler. Günümüzde yapay sinir ağı terimi istatistik, kavramsal psikoloji ve yapay zekâ alanlarında çalıştırılan sinir ağı modellerini ifade etmektedir. Merkezi

sinir sisteminin yapay sinir ağı ile simülasyonu teorik nörobilimin popüler bir konusudur.

Yapay sinir ağlarının modern yazılım uyarlamalarında konunun esin kaynağı olan biyolojik sistemlerin taklidi, pratik yaklaşımlarla hızlı problem çözümleri için terk edilmiş, bunun yerine istatistik ve sayısal işaret işleme algoritmaları ile desteklenmişlerdir. Bu sistemlerden bazılarında adaptif ve adaptif olmayan yapay sinir ağı bileşen olarak derlenmiştir. Farklı algoritmalar ile desteklense de veya gerçek dünya problemlerini daha pratik yollarla çözmek için farklılaştırılırsalar da yapay sinir ağlarının biyolojik sinir ağı ile benzerliği yerini korumaktadır. Düzgün doğrusal olmayan sinyal iletimi, dağıtık yapı, paralel, lokal işlem ve adaptasyon, yapay sinir ağı ile biyolojik sinir ağlarının, bilinen tüm uygulamalarda ve algoritma araştırmalarında, ortak özelliği olmuştur.

2.1 YAPAY ZEKÂ KAVRAMININ VE YAPAY SİNİR AĞLARININ GELİŞİMİ

İnsan beyni üzerinde yapılan çalışmalar binlerce yıl öncesine dayanır. Fakat modern çağın elektronik alanındaki gelişmeleri ile insan beyni ve düşünme sürecinin modellenip, taklit edilmesi mümkün olmuştur. Sinir ağı ile ilgili günümüzdeki çalışmalar, nörofizyolog Warren McCulloch ve matematikçi Walter Pitts'in 1943 yılında yaptığı araştırmalar ile itibar kazanmıştır. McCulloch, sinir sistemindeki düşünme, hissetme ve bunun gibi algıya bağlı dinamikler üzerinde yaklaşık yirmi yıl çalışmıştır. Walter Pitts ve McCulloch nöronların nasıl çalışabileceği konusunda ilk makaleleri yayınlamışlar ve basit elektrik devrelerini kullanarak ilkel yapay sinir ağı tasarlayıp üretmişlerdir. "Fomal Sinir Ağlarında McCulloch-Pitts Teorisi" ile akademik çevrelerde de kabul edilmişlerdir.

Sinir ağı teknolojisindeki bir sonraki önemli gelişme 1949 yılında Donald Hebb tarafından yazılan "The Organization of Behavior" (Hebb, 1949)¹⁵ kitabıyla doğmuştur. Bu kitap, McCulloch-Pitts'in nöronlar ve nasıl çalıştıklarıyla ilgili teorisini destekler ve ilaveler yapar. Kitapta bahsedilen, sonraki çalışmalara ve günümüz yapay sinir ağlarının tasarımına da ilham veren en önemli konu, nöral bağlantıların kullanıldığı her anda güçlenmeleridir. Günümüz modern yapay sinir ağı da, eğitim süreci tamamlandıktan sonra bu kurala bağlı olarak çalışmaktadırlar.

1950'ler boyunca fonksiyonel programlamanın ve analitik hesaplama yöntemlerinin gelişmesi, deneysel yapay sinir ağı çalışmalarına bir süre ara verilmesine neden olmuştur. Buna rağmen, konu ile ilgilenen bilim adamları bireysel çalışmalarına devam etmişlerdir. 1954 yılında Marvin Minsky, sinir ağı araştırmalarıyla ilgili "Theory of Neural-Analog Reinforcement Systems and its Application to the Brain-

¹⁵ Hebb, D. (1949). The Organization of Behavior.

Model Problem" isimli bir doktora tezi hazırlamıştır. Ardından yapay zekâ kavramını tartışan ilk bilimsel makale olan ve günümüzde yapay sinir ağları olarak bilinen teknoloji ile ilgi birçok bilgi ve ipucu içeren, "Steps Towards Artificial Intelligence"ı yayınlamıştır. 1956 yılında yapay zekâ konusuyla ilgili ilk kapsamlı araştırma projesi olan "Dartmouth Summer" projesi ile yapay zekâ ve yapay sinir ağları ile ilgili araştırmalar tekrar hız kazanmaya başlamıştır. Bu çalışmalar yapay sinir ağı uygulamalarının ilkel başlangıcı olmuştur.

Yıllar sonra, John von Neuman, telgraf yayını ve vakum tüpleri ile basitleştirilmiş nöron fonksiyonlarının taklidi üzerinde çalışmaya başlamıştır. Bu durum Von Neumann makinelerinin icadına öncülük etmiştir. McCulloch ve Pitt'in öncü makalesinin yayınlanmasından yaklaşık 15 yıl sonra, yapay sinir ağı araştırma alanına yeni bir yaklaşım getirilmiştir. 1958 yılında Cornell üniversitesinde nörobiyolog olan Frank Rosenblatt "perceptron" (algılayabilen en küçük birim) üzerinde çalışmaya başlamıştır. Bu çalışmanın ilerleyen bölümlerinde, prototip uygulamada kullanılan algoritmaların ilkel yapı taşı olan perceptron kavramına tekrar değinilecektir. Özetle perceptron algılayabilir ilk yapay sinir ağıdır. İlkel ve eski bir donanımla inşa edilmiş olan ilk perceptron, sinek gözündeki sinir hücreleri üzerinde yapılan araştırmalar sonucu geliştirilmiştir. Bu araştırmalar, bir sineğin gözüne yakın yapılmış bir tehlikeden kaçarken sinir hücrelerinde gerçekleşen kimyasal ve elektriksel uyarıların değişiminden bahseder. Ancak perceptron modelinin problem çözme yeteneklerinin sınırlı olduğu Minsky ve Papert tarafından ispat edilmiştir. (Minsky & Papert, 1969)¹⁶

1959 ve 1960 yılları arasında, ABD Stanford üniversitesinden Bernard Widrow ve Marcian Hoff, ADALINE (ADaptive LINEar Elements) ve MADELINE (Multiple ADaptive LINEar Elements) modelini geliştirmişlerdir. Bu modeller gerçek problemlere uygulanabilecek ve uygulanmış ilk yapay sinir ağlarıdır. ADALINE modeli yapay sinir ağları, telefon hatlarından iletilen ses üzerinde oluşan yankıyı kaldırmak için filtre olarak kullanılmıştır. Ancak bu yapay sinir ağı modelinin de uygulamada bazı kısıtları olduğu Minsky ve Papert tarafından ispat edilmiştir. (Minsky & Papert, 1969)

1969 ve 1981 yılları arasında yapay sinir ağları üzerinde yapılan çalışmalar daha da yoğunlaşmıştır (Haykin, 1995)¹⁷. Bu çalışmaların ilk şaşırtıcı sonuçları, yazarların ve film yapımcılarının da ilgisi çekmiş, yapay zekâ ve robotların insan ırkı ile iletişimi üzerine pek çok bilimkurgu roman yazılmış, film ve televizyon dizileri yapılmıştır. Bu yapıtlarda konu olarak, genellikle insanlığı ele geçiren, yaratıcılarına düşman olan zeki robotlar işlenmiştir. Bu toplumsal eğilim ve araştırmaların, yapay sinir ağlarının hayal edildiği gibi her şeyi yapamayacağını ortaya koyması, konunun ciddiyetini kaybetmesine ve çalışmaların bir süre duraklamasına sebep olmuştur.

¹⁶ Minsky, M., & Papert, S. (1969). Perceptrons. Cambridge: MIT Press.

¹⁷ Haykin, S. (1995). Neural Networks. New York: Macmillan College Publishing Company.

Yapay sinir ađları ile ilgili önemli bir diđer gelişme ise 1970’li yıllarda SOM (Self Organizing Maps) ađlarının bulunmasıdır (Haykin, 1995). Bu ađlar herhangi bir destekleyici öğrenme mekanizması olmadan verileri sınıflandırabilen ilk uygulamalar olmuştur.


1982 yılında ise John Hopfield yapay sinir ađları ile ilgili yeni bir yaklaşım ortaya koymuştur. Bu yaklaşımda Hopfield, yapay sinir ađları ile insan beyninin taklit edilmesinin deđil, sinir sisteminin yapısal özelliklerinden esinlenerek, dinamik problemleri çözebilecek makineler oluşturulmasının hedeflenmesi gerektiđini öne sürmüştür. Ayrıca, bu çalışmanın ilerleyen bölümlerinde de anlatılacak olan Hopfield ađlarının ilk ilkel örneklerini geliştirmiş, çalışmalarını matematiksel ve bilimsel temellere oturtarak bilim dünyasında yapay sinir ađlarının bir kez daha kabul görmesini ve çalışmaların tekrar hız kazanmasını sağlamıştır (Haykin, 1995).

Aynı dönemlerde Japonya’nın da yapay sinir ađları ve yapay sinir ađlarının yapabilecekleri üzerine araştırmalara başlayacağını duyurması ile ABD uluslararası araştırmaların gerisinde kalmamak için yapay zekâ ile ilgili araştırmalara ayrılan ödenekleri arttırmış ve konu politik olarak da gündeme gelmiştir.

1986 yılında gerçekleştirilen “Neural Networks for Computing” konferansına 1800 delege katılmıştır. Bu konferansta Rumelhart, Hinton ve Williams yapay sinir ađlarında geri yayılım algoritmasındaki gelişimler ile ilgili raporlarını sunmuşlardır. Yayınladıkları makalede geri yayılım algoritmasının çok katmanlı yapay sinir ađı uygulamalarındaki başarısını ortaya koymuşlardır.

1990’ların başından itibaren artık yapay zekâ ve yapay sinir ađları son derece popüler bir araştırma konusu olmuş ve konu ile ilgili farklı problemler üzerinde çok başarılı olabilen yüzlerce yöntem ve uygulama geliştirilmiştir. Günümüz teknolojisinde yapay sinir ađları ile ilgili sürekli yeni yöntemlerin ve uygulamaların geliştirilmesi devam etmektedir. Ayrıca elektronik endüstrisi tarafından da yapay sinir ađlarına özel ve onları yüksek performans ile çalıştırabilecek sayısal, analog ve optik elektronik entegre devreler üzerinde çalışılmaktadır.

2.2 BİYOLOJİK SİNİR AĞLARI VE YAPAY SİNİR AĞLARI



Şekil 2.1 Memeli Sinir Hücresi Yapısı


İnsan beyni, büyük sinir ağlarının varoluşunun doğadaki kanıtıdır. Yapay sinir ağları teoride, kavramsal ve algısal kontrol gerektiren görevleri gerçekleştirirken, insanların ve diğer canlıların başarılı olduğu kadar başarılı olabilir.

Beyin, hesaplama gerektiren algısal davranışları ve kontrol faaliyetlerini gerçekleştirebilecek kapasiteye sahiptir. Burada bahsedilen algısal davranışın tersi refleksif veya otonom davranıştır. Memeli bir canlı bir nesneye baktığında, bu nesneyi algıladıktan sonra, yani bu nesnenin ne olduğunu anladıktan sonra beyinde bu nesne ile ilişkilendirilen düşünce süreçleri başlar. Düşünsel sürecin sonunda da beyin motor nöronlara yani kaslara bağlı nöronlara sinyaller gönderir ve bedensel tepki oluşur. Beynin avantajı paralel işlemi etkili bir şekilde kullanmasıdır. Başka bir deyişle, yüksek paralel hesaplama yapısına ve kesin olmayan bilgileri işleme kapasitesine sahiptir. İnsan beyni 10 milyardan fazla ilişkili nörondan oluşur. Her bir nöron (Şekil 2.1) veriyi almak, işlemek ve iletmek için biyokimyasal reaksiyonları ve elektriksel iletimi kullanan bir hücredir.

Sinir liflerinin ağaca benzer ağ yapısı dendritler olarak adlandırılır. Bu dendritler hücre gövdesi ile hücre çekirdeğine bağlanır. Hücre gövdesinden uzayan akson denilen uzun tek lif, son kısmında iplikçi şekilde dallanır ve diğer nöronların sinapsları ile bağlanır.

Bir nörondan diğer nörona sinyal iletimi, sinapslardaki bağlantı noktalarından salgılanan özel iletken maddelerin oluşturduğu karmaşık kimyasal reaksiyonlar ile gerçekleşir. Sinyali alan hücre bu sinyali gövdesi boyunca gövde bölümlerinin elektrik potansiyellerini değiştirerek taşır. Eğer potansiyel eşik değerine erişirse, sinyal aksondan aşağı gönderilir ve hücre tetiklenir.

Yapay sinir ağlarının temel işlem birimleri, yapay sinirler veya nöronlar olarak adlandırılır. Nöronun sadeleştirilmiş matematiksel modelinde, sinapsların etkileri, bağlantı ağırlıkları ile nöronların tetiklenmesi ise geçiş fonksiyonları (transfer functions) ile temsil edilir. Yapay sinir ağlarının katmanları arasındaki bağlantılar ve bu bağlantıların üzerindeki sinyallerin toplamının sonraki katmandaki nörona girişi ile de biyolojik sinir ağlarının düzgün doğrusal olmayan yapısı taklit edilmiş olur. Nöron uyarılarından sonra, girdi sinyallerinin tamamı bağlantılar kullanılarak ağırlıklandırılır ve geçiş fonksiyonu ile iletilir. Sanal nöronun öğrenme kapasitesi seçilmiş öğrenme algoritmasına bağlı olarak güncellenmiş ağırlıklar ile belirlenir.



Şekil 2.2 Yapay sinir hücresi ve çok katmanlı yapay sinir ağı

Tipik bir yapay sinir hücresi ve çok katmanlı bir yapay sinir ağı Şekil 2.2 de gösterilmiştir. Şekil 2.2 ye bakarak (x_1, \dots, x_n) vektörü ile sisteme girilen ve oklarla gösterilen sinyalin, tek yönlü olarak çıkış sinyalini oluşturduğu görülmektedir. Nöronun çıkış değeri O , (2-1) denklemi ile ifade edilir.

$$O = f(net) = f \left(\sum_{j=1}^n w_j x_j \right) \quad (2-1)$$

Bu denklemde, w_j bağlantı ağırlığını, $f(net)$ fonksiyonu ise aktivasyon, bir diğer deyişle geçiş fonksiyonunu göstermektedir. "net" değişkeni, (2-2) ifadesinden anlaşılacağı gibi bağlantı ağırlıklarının giriş vektörü ile çarpımlarının toplamını göstermektedir.

$$net = w^T x = w_1 x_1 + \dots + w_n x_n \quad (2-2)$$

T ağırlıkların oluşturduğu matrisin transpozudur. En basit şekliyle bir nöronun durumu (2-3) mantıksal denklemi ile ifade edilebilir.

(2-3)

Bu denklemde kullanılan θ değişkenine eşik değeri denir. Giriş değerlerinin ağırlıkları ile çarpımının toplamı bir nörona iletiildiğinde, toplam bu nöronun eşik değerini aşıyorsa nöronun durumu 1 olur. Bu durum, nöronun tetiklendiği ve sonraki katmanlardaki nöronlara sinyal göndereceği anlamına gelir.

2.3 YAPAY SİNİR AĞI MİMARİLERİ

Temel yapay sinir ağı mimarisi üç farklı nöron katmanından oluşur. Bunlar giriş katmanı, gizli katman ve çıkış katmanıdır. İleri beslemeli ağlarda sinyal akışı giriş katmanından çıkış katmanına doğrudur. Sinyalin geri gidişine izin verilmez. Bu ağlarda veri işleme süreçleri birden çok yapay sinir hücresi ve yapay sinir ağı katmanında gerçekleşebilir ancak geri besleme gerçekleştirilmez.

Rekürsif (geri beslemeli) yapay sinir ağlarında ise, sistem birden çok sayıda geri besleme bağlantısı içerebilir. İleri beslemeli ağların tam aksine ağın dinamik özellikleri problem çözümünün anahtarıdır. Bazı durumlarda yapay sinir hücrelerinin aktivasyon değerlerine, ağ dengeli bir durumu ulaşıncaya kadar gevşetme süreci (relaxation process) denilen işlemler uygulanır. Böylece aktivasyon değerleri sabitlenmiş olur.

Diğer bir takım uygulamalarda ise yapay nöronların aktivasyonlarındaki kaotik değişimler oldukça belirgindir ve çıkış değerlerini ciddi şekilde etkilemektedir. Ancak bu tarz sistemlerin de çözmeye çalıştıkları problemler kaotik ve dinamik yapıda bileşenler içermektedir. Bazı sistemler ise birlikte çalıştıkları uygulamalara ve ihtiyaçlara göre şekillenmektedirler. (Elman ağları, adaptif rezonans teorisi ağları, rekabetçi ağlar). Bu mimarilerin dışında çözülmeye çalışan probleme göre yapıları ve eğitim algoritmaları çok farklı pek çok yapay sinir ağı mimarisi vardır. (Bishop, 1995)¹⁸

Bir yapay sinir ağı bir grup giriş verisine karşı beklenen bir grup çıkış verisi oluşturacak şekilde tasarlanmalıdır. Bu tez çalışmasında geliştirilen prototip uygulamada bulunan yapay sinir ağı, sayısal görüntünün ön işlemeden geçirilmesi ile oluşturulan bir piksel verisi vektörüne karşılık, bir sanatçı olasılıkları vektörü üretmektedir.

¹⁸ Bishop, C. M. (1995). Neural Networks for Pattern Recognition. Oxford: Oxford University Press.

Yapay sinir ağlarının hücreleri arasındaki bağlantıların ağırlıklarını, yani sistemin çıkışındaki etkinliğini belirlemek için çok çeşitli yöntemler bulunmaktadır. Bu yöntemlerden biri önceden bilinen doğru bilgiler ve doğru sonuçlar kullanılarak ağırlıkların ayarlanmasıdır. Başka bir yöntem ise yapay sinir ağlarını belirli örüntüler ile belirli bir ağırlık güncelleme kuralı dahilinde eğitmektir. Yapay sinir ağlarında eğitim üç temel başlık altında sınıflandırılabilir. Bu başlıklar gözetimli öğrenme, gözetimsiz öğrenme ve destekli öğrenmedir. Gözetimli öğrenmede yapay sinir ağına bir giriş verisi ile birlikte çıkış katmanındaki her bir sinir hücresinden beklenen çıkış değeri de verilir. Sinyal bir faz ileri yayıldıktan sonra sinir ağının çıktısı ile beklenen değerler arasındaki farklar ve hata çıkış katmanındaki her bir birim için hesaplanır. Daha sonra bu hata değerleri birimler arasındaki bağlantıların ağırlıklarını değiştirmek için belirli bir ağırlık güncelleme algoritmasıyla kullanılır. Bu algoritmalar genellikle ağırlıklardaki değişimin hatadaki değişime oranı yani hatanın bağlantı ağırlıklarına göre türevlendirilmesi ile çalışır. Bu tarz öğrenen sistemlere gözetimli denmesinin sebebi, bilinen ve doğru bilgiler ile eğitilmesidir.

Bu yöntemin en iyi bilinen uygulamaları geri yayılım algoritması, delta kuralı ve perseptron kuralıdır.

Gözetimsiz eğitimde ise çıkış birimleri, giriş birimlerine uygulanan örüntüleri sınıflandırabilecek şekilde eğitilir. Bu modelde, sistem giriş verisi popülasyonundaki belirgin nitelikleri istatistiksel olarak keşfeder. Gözetimli eğitimde olduğu gibi önceden belirlenmiş bir kategori veya sınıflandırma verisi sisteme verilmemektedir. Sistem giriş verilerinin girebileceği sınıfları kendisi belirlemelidir.

Destekli öğrenmede ise, yapay sinir ağı durumları aksiyonlarla nasıl eşleştireceğini kendisi bulur ve sistemdeki nümerik ödül değerini maksimumda tutmaya çalışır. Sistem hangi giriş verileriyle hangi aksiyonu alacağına kendisi karar verir. En ilginç ve zor durumlarda ise aksiyonlar anlık ödülü tetiklemeyle kalmaz bulunduğu fazı takip eden tüm fazları etkiler. Bu iki karakteristik, deneme-yanılma ve geciktirilmiş ödüllendirme bu sistemlerin ayırtıcı özellikleridir. Biyolojik sinir ağlarında da bu durum, özellikle temel ihtiyaçların karşılanmasında hormon sistemleri ile desteklenir. Örneğin bir canlı beslenirken kendi hormon sistemleri tarafından ödüllendirir. Ancak merkezi sinir sistemi bu ödülü almasını sağlayan önceki durum ve koşulları yani besini elde etmesini sağlayan süreci de öğrenmiş ve ödül ile ilişkilendirmiştir.

2.4 YAPAY SİNİR AĞLARINDA ÖĞRENME

2.4.1 Hebbian Öğrenmesi ve Hebb İlkesi

Yapay sinir ağı mimarilerinde bahsedilen modeller, sadece birimler arası ağırlıkların değerlerini belirli bir güncelleme kuralına göre ayarlayan sistemlerdir. Bu tarz yaklaşımlara bağlantıcı (connectionist) sistem denir ve biyolojik sinir hücrelerinden esinlenerek geliştirildiğinden önceki bölümlerde de bahsedilmiştir. 1949 yılında

Hebb (Hebb, 1949) sinir hücrelerinin davranışsal yapısına göre bir teori geliştirmiştir. Bu teori bağlantıcı yapay sinir ağları için en etkili gelişmelerden biri olmuştur. Hebb'in çalışmasından çıkartılan en önemli konsept (Hebb ilkesi olarak da bilinir) öğrenmenin nasıl olması gerektiğiyle ilgilidir.

Öğrenme sinir hücreleri arasındaki sinaptik bağlantıların değişimi ile olmaktadır. Yani, bir A hücresinin aksonu bir B hücresini etkileyebilecek kadar ona yakınsa, tekrarlı ve ısrarcı bir biçimde B hücresini tetikliyorsa, sinir hücrelerinin birinde veya her ikisinde de A hücresinin B hücresini daha rahat tetikleyebilmesi için metabolik ve yapısal gelişimler gözlemlenir. Bu ifadeye dayandırılan yapay sinir ağı eğitim prensiplerinin tamamına Hebb Öğrenmesi denilebilir.

Aslında günümüzde kullanılan pek çok yapay sinir ağının eğitim teknikleri Hebb öğrenmesinin farklı algoritmik yaklaşımlarıdır. Burada bahsedilen teori özetle şöyledir. Eğer iki nöron ardışık olarak tetikleniyorlarsa aralarındaki bağlantı güçlendirilmelidir. Tek katmanlı iki hücreli bir ağ düşünürsek, bir birim girişi ve bir birimde çıkış olacaktır. Verileri giriş ve beklenen çıkış ikilileri olarak düşünürsek aşağıdaki formül ile sinir ağındaki tek bağlantının ağırlığı hesaplanabilir. (2-4) ifadesinde , girilen değerleri için beklenen çıkış değeridir.

(2-4)

Bu öğrenme yönteminin pratik kullanımında, eğitim verisi doğru bir şekilde normalize edilmediyse bağlantı ağırlıkları sürekli büyümektedir. Bu durum algoritmanın yazılım uygulamasını kullanılmaz hale getirmektedir.

2.4.2 Perseptron Öğrenme Kuralı

Perseptron (İngilizce “perceptron”) , İngilizcedeki “perception” yani algı ve “atom” sözcüklerinden oluşturulmuştur. Yapay sinir ağları literatürü incelendiğinde algılayabilen en küçük birim olarak da ifade edilebilir. Perseptron ağırlık ve öztetikleme (bias) değerlerini girilen veriye göre güncelleyebilen tek katmanlı ve en küçük yapay sinir ağıdır. Bu sinir ağlarının eğitiminde kullanılan tekniğe “Perseptron Öğrenme Kuralı” denir. Perseptronlar özellikle basit örüntü sınıflandırma problemlerini çözmeye uygundur. Elimizde x ve x girişleri için yapay sinir ağından üretmesini beklediğimiz çıkış değeri $d(k)$ ikililerinden oluşan bir eğitim veri kümesi olduğunu düşünelim. Bir sınıflandırma problemi için $d(k)$ genellikle +1 veya -1 olarak seçilir. Perseptron öğrenme kuralı çok basittir ve aşağıdaki gibi ifade edilebilir:

1. Birimler arası bağlantı ağırlıklarına başlangıç değeri olarak rastgele değerler atılır.
2. Eğitim kümesindeki örneklerden bir x vektörü seçilir.

3. Yapay sinir ağından çıkış yapılır.
4. Eğer yapay sinir ağı beklenen $d(k)$ değerini veya bu değere kabul edilebilir bir uzaklıkta çıkış değeri üretmediyse, tüm bağlantıların ağırlıkları aşağıdaki formül ile güncellenir:
5. $\Delta w_i = \eta(d_k - y_k)x_i$; (η = öğrenme katsayısı)
6. 2. adıma geri dönlür.

Bu yaklaşımın Hebb öğrenme kuralına göre tek farkı, ağın doğru veya kabul edilebilir bir yanıt vermesi durumunda bağlantıların ağırlıklarının güncellenmemesidir.

2.4.3 Geri Yayılım Öğrenmesi

Perseptron öğrenme kuralı çok basittir ve yalnızca düzgün doğrusal bileşenlerine ayrıştırılabilen fonksiyonların analizine ve öğrenilmesine izin verir. Hesaplanan hatanın türevini alırsak, hatanın yönü ve ağıın hangi yönde hata yaptığı bilgisini de bulmuş oluruz. Eğer hatanın türevinin negatif değerini alırsak ve bu değeri ağırlıklara ekleyerek eğitime devam edersek, hata değeri gittikçe azalır ve yapay sinir ağıları ile analiz etmeye, taklit etmeye çalıştığımız fonksiyonu işlerken yapay sinir ağıının oluşturduğu hata fonksiyonunun lokal minimumuna yaklaşmış oluruz. Bu hesaplama, hatanın türevi pozitif ise ağırlık arttırıldıkça hatanın da arttığını, negatif ise ağırlık arttırıldıkça hatanın azaldığını gösterir.

Bu yöntem birden fazla katmanlı yapay sinir ağlarında şöyle uygulanır. Çıkış katmanından başlanıp, gizli katmandan, giriş katmanına doğru, her katman için hatanın kısmi türevinin değeri ile yukarıdaki paragraftaki gibi ağırlıklar güncellenerek uygulanır. Burada kısmi türev, ağırlıklar kullanılarak hesaplanır. Hangi birimin ağırlığı, ne kadar hatayı arttıracak yönde ise yani hatadaki payı ne kadar yüksek ise, ağırlıkları o ölçüde güncellenir. Bu algoritma çıkış katmanında başlayıp, giriş katmanına doğru ağırlıkları güncellediğinden geri yayılım algoritması olarak adlandırılmıştır.

Bir yapay sinir ağı bu yöntemle, çevrimiçi(“online”) ve toplu(“batch”) olmak üzere iki farklı şekilde eğitilebilir. İki yöntemde de ağırlık güncelleme sayısı eşittir ancak veriler yapay sinir ağına çok farklı şekillerde sunulur. Çevrimiçi metotta eğitim kümesi içindeki her bir örnek veri için teker teker ağırlık güncellemesi yapılır. Buna alternatif başka bir yöntem ise tüm veri için ağırlık güncellemelerini hesaplamak ancak güncellemeleri gerçekleştirmeden bu değişiklikleri toplayarak saklamaktır. Eğitim setindeki tüm veri için gerekli ağırlık güncellemeleri hesaplanıp toplandıktan sonra, elde edilen kümülâtif ağırlık değişimi sisteme uygulanır. Teker teker tüm veriler için güncelleme yapmaktan daha başarılı bir yöntemdir ve çıkış fonksiyonunda aranan gradyana daha rahat ulaşılmasını sağlar. Bu işlem hata kabul edilebilir bir düzeye gelinceye kadar tekrarlanır ve yapay sinir ağı literatüründe iterasyon (epoch) olarak bilinir. Bu yöntemde hata da kümülâtif olarak her bir veri örneği için oluşan hatanın karelerinin toplamı şeklinde hesaplanır. Bu kümülâtif hatanın ortalaması alınarak hatanın türevini bulmak daha kolaydır. Hata

hesaplandıktan sonra ağırlık güncellemeleri teker teker gerçekleştirilir. Bu işlem tüm veri kümesi için (2-5) ile ifade edilir.

$$\Delta w_{ij}(n) = -\eta^* \frac{\delta E}{\delta w_{ij}} + \alpha^* \Delta w_{ij}(n - 1) \quad (2-5)$$


Bu formülde η öğrenme katsayısının ve α da momentumun değeridir. Momentum formülünden de anlaşılacağı üzere bir önceki adımdaki ağırlık değişiminin şimdiki değişime etkisidir. Etkin ve hızlı bir eğitim için öğrenme katsayısı ve momentum değerleri iyi seçilmiş olmalıdır. İyi bir öğrenme katsayısı ve momentum değeri belirlemek için yaygın olarak kullanılan yöntem, eğitim ve test verileri kümeleri üzerinde tekrarlanan deneyler yapmak ve başarının ölçülmesidir. Geri yayılım algoritmasının, yeterli sayıda gizli katman ile herhangi bir doğrusal olmayan fonksiyonu başarıyla taklit edebildiği ispatlanmıştır. Bu ispat geri yayılım algoritmasını, sinyal tahmini ve sistem modelleme için iyi bir aday haline getirmiştir.

2.5 YAPAY SİNİR AĞLARINDA EĞİTİM VE TEST

Yapay Sinir Ağlarının eğitimi prosedürünün iyileştirilmesinin bilinen temel yollarından birisi, geniş bir eğitim örnek kümesi kullanılmasıdır. Özellikle problemler karmaşıktıkça, eğitim kümesinin genişliği yapay sinir ağının başarısını önemli ölçüde etkilemektedir. Güçlü ve güvenilir bir yapay sinir ağı oluşturmak için bazı durumlarda eğitim verisine bilinçli olarak gürültü ve doğal sapmalar eklenebilir. Bu işlem yapay sinir ağının gürültüye karşı nasıl davranması gerektiğini öğrenmesini sağlar. Zayıf eğitim kümeleri yapay sinir ağının güvenilir olmaktan uzak ve tahmin edilemez bir model sergilemesine sebep olabilmektedir.

Sinir ağları genellikle kabul edilebilir bir hata değerine kadar eğitim algoritmasının iteratif uygulanması şeklinde eğitilir. Hata çözülmeye çalışılan problem için kabul edilebilir bir değere düştüğünde eğitim durdurulur. Burada yapay sinir ağının aşırı eğitimi sonucunda da bazı problemler ile karşılaşılabilir. Bu da yapay sinir ağının eğitim kümesi içindeki veri noktalarını tamamen doğru şekilde tanımlayabilmesine ancak eğitim seti dışındaki benzer veriyi modelleyememesine sebep olur. Şekil 2.3 de aşırı eğitilmiş ve doğru eğitilmiş iki yapay sinir ağına ait sınıflandırma örneği gösterilmektedir. Bu şekilde X ve Y değerlerine göre sınıflandırılan veri noktalarından yuvarlaklar eğitim kümesi içerisinde bulunan veriler diğerleri ise test verileridir. Birinci şekilde gösterilen yapay sinir ağı eğitim aşamasında görmediği test ve eğitim verilerini doğru sınıflar altına yerleştirebilirken ikinci yapay sinir ağı aynı başarıyı gösterememektedir. Burada birinci yapay sinir ağı sistemin genel parametrelerini iyi öğrenmiş ve dolayısı ile girilen veriler için başarılı genelleme yapabilmektedir. Ancak ikinci sinir ağı aşırı eğitildiği için sistemin genel modeline

göre global genellemeyi başaramamış bunun yerine giriş çıkış ikililerini ezberleyen bir belleğe dönüşmüştür. (Fausett, 1994)¹⁹



Şekil 2.3 Sırasıyla, doğru eğitilmiş sinir ağı sınıflandırması ve aşırı eğitilmiş sinir ağı sınıflandırması

2.5.1 Nöron Sayısının Seçimi

Yapay sinir ağlarının saklı katmanlarındaki nöron sayısı, ağın veri örneklerini ne kadar başarılı ayrıştırabileceği ile doğru orantılıdır. Saklı katmanında çok sayıda nörona sahip olan bir sinir ağı doğru öğrenmeyi gerçekleştirebilir ve eğitim verilerini doğru bir şekilde modelleyebilir. Ancak eğitim kümesinin dışındaki verileri genelleme yeteneği düşer ve aşırı öğrenme problemleri sergileyebilir. Saklı katmanında çok az sayıda nöron bulunan bir sinir ağı ise eğitim kümesindeki veriler arasındaki gizli ilişkileri ve örüntüleri öğrenemeyebilir ve hata kabul edilebilir limitlerin üzerinde kalır. Bu durum saklı katmanlardaki nöron sayısının seçimini, yapay sinir ağının başarısını etkileyen kritik bir parametre haline getirmektedir.

2.5.2 İlk Ağırlıkların Seçimi

Yapay sinir ağları öğrenme algoritmalarının tamamı, nöronlar arasındaki ağırlıklarda küçük değişiklikler yaparak hatayı düşürme prensibi üzerine kurulmuşlardır. Birçok yapay sinir ağı sisteminde bağlantıların ilk ağırlıklarına rastgele değerler atanır. Bu tez çalışmasında da yapay sinir ağının ilk ağırlıkları rastgele atanmıştır. Ancak çalışmalar göstermektedir ki farklı ilk ağırlık değerlerine göre ve öğrenme algoritmalarının yapısına bağlı olarak başarımlar değişebilmektedir. Çalışmadaki prototip uygulamada kullanılan “Contrastive Divergence” algoritmasının başarımı ilk ağırlıklara çok bağlı değildir ancak geri yayılım için aynısı söylenemez. Geri yayılım algoritmasının hatadaki yerel minimumlara takıldığı bilinmektedir. Ağırlık seçimi için farklı algoritmalar kullanılmakla beraber, deneme yanılma da sıklıkla kullanılan bir yöntemdir.

¹⁹ Fausett, L. (1994). Fundamentals of Neural Networks. PrenticeHall.

2.5.3 Öğrenme Katsayısının Seçimi


Öğrenme katsayısı, çok boyutlu ağırlık uzayında, ağırlıklar değiştirilirken atılacak adımların büyüklüğünü yani ağırlıklar üzerinde yapılacak değer güncellemesinin ne büyüklükte olacağını göstermektedir. Eğer seçilen öğrenme katsayısı çok büyük ise hatadaki yerel minimum değeri sürekli aşılabilir. Yani doğru değer sürekli olarak aşılabilir. Öğrenme katsayısı düşük olduğunda ise sistemi eğitmek için daha fazla sayıda eğitim iterasyonuna ihtiyaç duyulur. Bu da sistemin daha yavaş öğrenmesine sebep olur.

Bu bölümde bahsedilen yapay sinir ağlarının temel özellikleri, temel kavramları ve biyolojik sistemlerle benzerlikleri bu tez çalışması kapsamında geliştirilen prototip uygulama için ve prototip uygulamada kullanılan algoritmalar için de aynen geçerlidir.

3 YAPAY SİNİR AĞLARINDA OLASILIKSAL YAKLAŞIMLAR VE BOLTZMANN MAKİNELERİ

Bu tez çalışması kapsamında geliştirilen prototip uygulamada rekürsif ve olasılıksal yapay sinir ağlarından Boltzmann Makineleri algoritmalarından Kısıtlı ve Durumsal Kısıtlı Boltzmann Makineleri algoritmaları kullanılmıştır. Prototip uygulamada Kısıtlı Boltzmann Makineleri algoritmalarının neden kullanıldığının daha iyi anlaşılabilmesi için bu bölümde yapay sinir ağlarında rekürsiflik ve olasılıksallık kavramlarına değinilecek ve Boltzmann Makineleri anlatılacaktır.

3.1 REKÜRSİF AĞLAR




Şekil 3.1 Rekürsif bir ağ modeli

Rekürsif yapay sinir ağları düzgün doğrusal olmayan zaman serilerinin tahmini, veri modeli sistemi ve örüntü tanıma, zamana bağlı örüntü tanıma ve benzer düzgün doğrusal bağıntılar içermeyen kaotik veya dinamik sistemlerin analizi gibi konularda kullanılan modern yapay sinir ağı teknolojisidir. Bu yapıdaki sinir ağlarının $(t+1)$ anındaki çıkışı, t anındaki girişine bağımlı bir dinamiklik gösterir. (Mandic &

Chambers, 2001)²⁰ Rekürsif sinir ağlarının zamana bağlı sistemlerde büyük başarı gösterdiği tespit edilmiştir.

Rekürsif bir yapay sinir ağı, klasik ileri beslemeli bir yapay sinir ağına, çıkış katmanının son değerlerini tutacak ve (t+1) anındaki giriş ile birlikte bu değeri kullanacak bir hafıza katmanı eklenerek oluşturulabilir. Bilim adamları tarafından farklı problem çeşitleri üzerine geliştirilmiş birçok rekürsif yapay sinir ağı algoritması ve mimarisi bulunmaktadır. Bunlardan bazıları Elman ağı (Cruse), Jordan ağı, MMC ağı (Pfeifer, Blumberg, Meyer, & Wilson)²¹ (CRUSE, STEINKÜHLER, & BURKAMP, 1998)²², Hopfield ağı (Şekil 3.3), eko durum ağı (Echo state network), uzun kısa dönemli bellek ağı (Long short term memory network) gibi sıralanabilir.

Bu tez çalışmasında ve kapsam dahilinde geliştirilen prototip uygulamada kullanılan Boltzmann Makineleri (Şekil 3.2), Hopfield ağlarının temel prensipleri kullanılarak, pratik yazılım uygulamaları ve gerçek dünya problemlerinin güvenilir bir şekilde çözümü için geliştirilmiş bir yapay sinir ağıdır. Hopfield ağları bağlantı ağırlıklarını güncellemek için gradyan yaklaşımı kullanırken, Boltzmann makineleri Gibbs örnekleme kullanmaktadır. Ayrıca Hopfield ağları nöronların durumlarını deterministik olarak güncellerken, Boltzmann makineleri nöronların durumlarını olasılıksal olarak güncellemektedir. Hopfield ağları ve Boltzmann makineleri enerji temelli yapay sinir ağlarıdır. Çalışmanın ilerleyen bölümlerinde enerji hesaplamalarından ve yapay sinir ağlarındaki uygulamalarından bahsedilecektir.




Şekil 3.2 Boltzmann Makinesi Grafi

²⁰ Mandic, D., & Chambers, J. (2001). Recurrent Neural Networks for Prediction: Learning Algorithms, Architectures and Stability. New York: John Wiley & Sons.

²¹ Pfeifer, R., Blumberg, B., Meyer, J.-A., & Wilson, S. From Animal to Animats 5. Cambridge: MIT Press.

²² CRUSE, H., STEINKÜHLER, U., & BURKAMP, C. (1998). MMC - a recurrent neural network which can be used as manipulable body model.



Şekil 3.3 Hopfield Ağı Grafi

3.2 OLASILIKSAL (STOCHASTIC) SİNİR AĞLARI

Bu bölüme kadar bahsettiğimiz Boltzmann Makineleri dışındaki tüm yapay sinir ağları, giriş ve çıkış değerleri göz önünde bulundurulduğunda deterministik, bir diğer deyişle önceden hesaplanabilir davranışlar sergilemektedir. Bu sinir ağları, nöronları arasındaki bağlantılara atanmış belirli ağırlıklar ile çalıştırıldıklarında bir noktada dengelenmekte ve aynı girişler için aynı çıkışları üretmektedirler. Bu şekilde davranmalarının nedeni bu ağları oluşturan nöronların, ağların yapısı gereği olasılıksal bileşenler içermemesidir.

Örüntü tamamlama, kayıp veriyi tahmin etme ve eksik veya yetersiz eğitim verileri ile örüntü sınıflandırma gibi problemlerde, olasılıksal ağların istatistiksel tahminleme özelliği, onlara avantaj sağlamaktadır. Problem yapay sinir ağının ilk durumuna, eğitim verisi ve kısıtlamalar da nöronlar arası bağlantılara kodlanmıştır. Bu noktadan sonra sinir ağından bunda önce bahsettiğimiz gibi belirli girişler için belirli çıkışlar üretmesi değil, gerçek dünyadan alınan verinin olasılık dağılımını modellemesi beklenmektedir. Yani sistemin eğitim verisinden yola çıkarak eğitim verisi içerisinde keşfettiği özelliklerin olasılık dağılımını modellemesi ve benzerlerini üretmesi beklenmektedir. Yeterince veri ile eğitildiğinde bu sistem eğitim verisine çok benzer olasılık dağılımları üretebilir. Bu tarz sistemlerin başarımı eğitim verisindeki dağılım ile sistemin ürettiği dağılım arasındaki benzerlik ile ölçülür. Olasılıksal bir sinir ağından seçilen rastgele bir nöron, durum değeri ile birlikte alındığında ve sinir ağının tüm bağlantı ağırlık değerleri bilinse bile bu nöronun bir sonraki değerini ne olacağının kesin değeri hesaplanamaz. Ancak yeni durumunun ne olacağı olasılığı hesaplanabilir.

Olasılıksal bir sistem verinin kaybolmuş veya bozulmuş olan kısmını işte bu şekilde tahmin etmektedir. Bu çalışmada geliştirilen prototip uygulamanın ilk katmanı olan Kısıtlı Boltzmann makinesi olasılıksal bir sistemdir ve sisteme girilen görüntü üzerindeki veriden görüntünün gürültü ile kaybolmuş veya bozulmuş kısımlarının olasılıklarını tahmin edebilmekte ve bu görüntünün hangi sanatçıya ait olabileceğinin kararı bu olasılık dağılımlarına göre uygulamanın ikinci katmanında verilmektedir.

3.3 BOLTZMAN MAKİNELERİ

Boltzmann makineleri birbirlerine simetrik olarak bağlantılı nöron benzeri yapılardan oluşan ve durumlarının açık veya kapalı olması konusunda olasılıksal kararlar verebilen birimlerden oluşan bir yapay sinir ağı türüdür. Boltzmann makinelerinin göreceli olarak basit bir öğrenme algoritması vardır. (Hinton & Sejnowski, Optimal Perceptual Inference, 1983)²³ Bu algoritma eğitim veri kümesi içerisinde bulunan karmaşık düzenlilik özelliklerini keşfedebilir. Çok katmanlı özellik, öznitelik buluculardan oluşan Boltzmann Makinelerinde eğitim çok yavaştır. Ancak tek katmanlı özellik bulucusu, saklı katmanı bulunan Kısıtlı Boltzmann Makinelerinde öğrenme çok daha hızlıdır. Birinin gizli katmanı ve bulunduğu öznitelikler, diğer bir ağın görünür katmanı ve girdisi olarak ardışık biçimde çalıştırılan Kısıtlı Boltzmann Makineleri ile efektif bir öğrenme ve özellik keşfetme sistemi oluşturulabilir.

Boltzmann Makineleri iki farklı hesaplama problemini çözebilir. Bir arama problemi için makinenin bağlantı ağırlıkları sabitlenir ve bir maliyet fonksiyonunu ifade etmesi sağlanabilir. Bu şekilde çalıştırılırsa makinenin olasılıksal dinamikleri, düşük maliyetli değer vektörleri üretmesine izin verir.

Başka bir öğrenme probleminde ise makineye ikili sayılardan oluşan öğrenme verisi vektörleri verilir. Bu süreçte makine yüksek olasılık değerleri ile bu vektörleri üretmeyi öğrenmelidir. Bunu yapabilmek için, yapay nöronları arasında öyle bağlantılar bulmalıdır ki diğer olası sonuç vektörlerine göre eğitim verisi vektörleri daha düşük maliyetli olmalıdır. Bir öğrenme problemini çözmek için Boltzmann makinesi ağırlıklarında birçok küçük değişiklik yapar ve her bir değişiklik aslında yeni bir arama problemidir.

3.4 BOLTZMANN MAKİNELERİNİN OLASILIKSAL DİNAMİKLERİ

Boltzmann makinesinin ağında bulunan bir i birimi durumunu güncelleyeceği zaman öncelikle toplam girişini hesaplar. Bu toplam, **(3-1)** kendi üzerindeki besleme (bias) değerinin ve diğer aktif nöronlar ile arasındaki bağlantı ağırlıklarının toplamıdır.

²³ Hinton, G. E., & Sejnowski, T. J. (1983). Optimal Perceptual Inference. Proceedings of the IEEE conference on Computer Vision and Pattern Recognition (s. 448-453). Washington DC: IEEE.

$$z_i = b_i + \sum_j s_j w_{ij} \quad (3-1)$$

Burada s_j , w_{ij} ve b_i birimleri arasındaki bağlantının ağırlığıdır. s_i ise nöron biriminin aktif olduğu durumda 1, pasif olduğu durumda 0 değerini alır. s_i nöron biriminin aktif olma, yani durumunun 1 olma olasılığı (3-2) lojistik fonksiyon denklemindeki gibidir.

$$prob(s_i = 1) = \frac{1}{1 + e^{-z_i}} \quad (3-2)$$

Eğer birimlerin durumları birbirlerinin toplam giriş değerleri değişmeyecek sıralama ile ardışık olarak güncellenirse, yapay sinir ağı Boltzmann durumu denilen dağılıma ulaşacaktır. Bu durumda belirli bir durum vektörünün olasılığı yalnızca bu durum vektörünün sistem üzerinde oluşturduğu enerjinin diğer olası durum vektörlerinin oluşturacağı enerjilere oranına bağlıdır.

$$P(\mathbf{v}) = e^{-E(\mathbf{v})} / \sum_u e^{-E(\mathbf{u})} \quad (3-3)$$

Hopfield ağlarında da olduğu gibi bir durum vektörünün enerjisi aşağıdaki denklem ile tanımlanır.

$$E(\mathbf{v}) = - \sum_i s_i^v b_i - \sum_{i < j} s_i^v s_j^v w_{ij} \quad (3-4)$$

Bu denklemde s_i^v , birimine v durum vektöründen denk düşen değerdir.

Eğer bağlantılar üzerindeki ağırlıklar, durum vektörlerinin sistem üzerinde oluşturduğu enerjinin bu vektörlerin maliyetlerini temsil edeceği şekilde seçilirse, Boltzmann makinesinin olasılıksal dinamikleri zayıf yerel çözümlerden, düşük maliyetli çözümler üreterek uzak kalabilen bir sistem olarak düşünülebilir. s_i^v birimine uygulanan toplam giriş z_i , bu birimin aktif olması ile pasif olması durumunda oluşacak enerji değerleri arasındaki farkı temsil etmektedir. Ayrıca bu durum s_i^v negatif bir değer olsa bile biriminin sürekli aktif olabileceğini bu da sistem enerjisinin sürekli artabileceğini ve sistemin enerji bariyerlerini aşabileceği anlamına gelir.

Bu arama benzetilmiş tavlama (simulated annealing) metodu kullanılarak geliştirilebilir.

3.5 BENZETİLMİŞ TAVLAMA (SIMULATED ANNEALING) METODU

Uygulamalı matematikte bir arama uzayındaki fonksiyonun global optimum değerlerini bulmak için kullanılan bu metot, 1983'de Scott Kirkpatrick, C. Daniel Gelatt ve Mario P. Vecchi tarafından , (Kirkpatrick, Gelatt, & Vecchi, 1983)²⁴ ve 1985'de Vlado Černý tarafından birbirlerinden bağımsız olarak açıklanmıştır. (Cerny, 1985)²⁵ Uygulamada algoritma, Metropolis-Hastings algoritmasının bir uyarlamasıdır. Termodinamik bir sistem için örnek durumlar oluşturan ilk uygulama (Monte Carlo uygulaması) , 1953'de N. Metropolis tarafından geliştirilmiştir. (Metropolis, Rosenbluth, Rosenbluth, Teller, & Teller, 1953)²⁶


Benzetilmiş tavlama algoritması, pek çok değişkene sahip fonksiyonların en büyük veya en küçük değerlerinin bulunması ve özellikle pek çok yerel en küçük değere sahip doğrusal olmayan fonksiyonların en küçük değerlerinin bulunması için tasarlanmıştır. Bu algoritma ve türevleri, katı cisimlerin soğurken mükemmel şekilde atomik dizilişlerini örnek aldığından ve özellikle metallerin (örneğin: çelik) tavlama işlemini andırdığından bu ismi almıştır. Diğer olasılıksal yaklaşımlar gibi en iyi çözümün en kısa zamanda üretimini sağlar. Bu sebeple, özellikle matematiksel modellerle gösterilemeyen kombinasyonel problemlerin eniyileme uygulamalarında tercih edilir.

Bu algoritma şöyle bir örnekle benzeştirilebilir. Yapay sinir ağı çok delikli bir golf sahasının en alçak noktasını aramaktadır. Buradaki çok delikli golf sahası hata fonksiyonunu temsil etmektedir. Eğer algoritma sahanın eğimi yönünde ilerlemek gibi basit bir yöntem kullanırsa o zaman yüksek olasılıkla deliklerden birinde takılabilir. Geri yayılım algoritmasında gözlemlenen problem budur. Bunun yerine algoritma sahaya bir top koyup araziye olduğu gibi sallamaya başlarsa, top arada bir deliklere girse de sürekli sallandığı için deliklerden çıkar. Zamanla algoritma sallama hızını ağır ağır azaltılır. Tamamen durduğunda ise topun sahanın en alçak noktasında (genel minimum) ya da yakın bir yerlerde olduğu kabul edilebilir.

²⁴ Kirkpatrick, S., Gelatt, C. D., & Vecchi, M. P. (1983). Optimization by Simulated Annealing.

²⁵ Cerny, V. (1985). A thermodynamical approach to the travelling salesman problem: an efficient simulation algorithm. *Journal of Optimization Theory and Applications* , 45 , 41-51.

²⁶ Metropolis, N., Rosenbluth, A., Rosenbluth, M., Teller, A., & Teller, E. (1953). Equations of State Calculations by Fast Computing Machines. *Journal of Chemical Physics*, 21(6) , 1087-1092.



Şekil 3.4 Benzetilmiş tavlama metodu ile hata fonksiyonunun minimizasyonu

Gerçek dünyadaki katı cisimlerde de durum bu örnektene benzer. Örnekteki sallama hareketi cisimlerin sıcaklığına karşılık gelir. Bir gazı soğuturken atomlar bir süre sonra nasıl ki periyodik aralıklarla dizilip potansiyel enerjiyi minimize ediyorlar ise (kristalleşme) algoritma da aynı yöntemi kullanarak enerjiyi değil tahmin etmeye çalıştığı fonksiyonda çalışırken yaptığı hatayı minimize etmeye çalışmaktadır.


Bu yöntemin yapay sinir ağının bölgesel en iyi çözümlere (local optimum) takılmasını engeller. Soğutma işlemi bu algoritmada daha iyi sonuçların bulunmasını sağlayacak yeni komşu çözümlerin üretilmesini sağlayan üstel (exponential) bir ifadedir.

Benzetilmiş tavlama algoritması; elektronik devre tasarımı, görüntü işleme, yol bulma problemleri, seyahat problemleri, malzeme fiziği benzetimi, kesme ve paketleme problemleri, iş/akış çizelgeleme ve benzeri pek çok problemin çözümünde kullanılabilir.

Boltzmann makinelerinde ise bu yaklaşım enerji sistemine fiziksel sistemlerdekine benzer bir T (sıcaklık) değişkeninin eklenmesi ile uygulanır. Tüm ağırlıklar ve enerjiler bu T değişkeni ile küçültülür. T sıcaklık değerini büyük bir ilk değerden küçük bir son değere doğru küçülterek hem sistemin hızla dengelenmesi hem de düşük maliyetli çözümlerin yüksek maliyetli çözümlere oranla olasılığının artırılması sağlanabilir. Sıcaklık $T = 0$ iken güncelleme kuralı rastgeleliğini kaybeder ve deterministik bir Hopfield Ağı gibi davranır. Burada T değişkeninin oluşturduğu değişkenliğe termal gürültü de denir.

3.6 KISITLI VE DURUMSAL BOLTZMANN MAKİNELERİ

3.6.1 Kısıtlı Boltzmann Makineleri



Şekil 3.5 Temsili Kısıtlı Boltzmann Makinesi Grafi

Kısıtlı Boltzmann Makinesi (Restricted Boltzmann Machine) (Smolensky, 1986)²⁷, gizli (h) ve görünür (v) katman adı verilen iki katmanlı bir olasılık graf modelidir.

Katmanlardaki birimler (yapay nöronlar) bir diğer katmandaki birimler ile bağımlı ancak kendi aralarında bağımsızdır. Bu özelliği ile eğitim süreçleri klasik Boltzmann makinelerine, Hopfield ağları ve diğer benzer nedensel enerji sistemlerine göre çok daha basit ve hızlıdır. (Pearl, 1988)²⁸

Gizli katmandaki ve görünür katmandaki birimler katmanlar içinde bağımsız oldukları için durumları hesaplanırken fazladan iterasyonlara gerek yoktur. Ayrıca algoritmanın uygulaması sırasında da programatik olarak çoklu iş parçacıkları kullanılabilir (threads). Böylece çok çekirdekli işlemciler ve grafik işlemciler algoritmanın performansını arttırmak için rahatlıkla kullanılabilir (McAfee, 2009)²⁹. Giriş verisi ile ilk durumları belirlenen görünür katmandan bir S_i birimi seçildiğinde gizli katmandaki S_j biriminin durumunun aktif olma olasılığı (3-5) bağlantısı ile hesaplanır.

²⁷ Smolensky, P. (1986). Parallel distributed processing: explorations in the microstructure of cognition, vol. 1. P. Smolensky içinde, Parallel distributed processing: explorations in the microstructure of cognition, vol. 1 (s. 194–281). Cambridge: MIT Press.

²⁸ Pearl, J. (1988). Probabilistic reasoning in intelligent systems : networks of plausible inference. San Mateo: Morgan Kaufmann Publishers.

²⁹ McAfee, L. (2009). Design and Analysis of BLAS, GPU, and Sparse Multithreaded Acceleration Methods for Restricted Boltzmann Machine Training.

$$p(s_j = 1) = \frac{1}{1 + \exp(-\sum_i w_{ij} s_i)} \quad (3-5)$$

Kısıtlı Boltzmann Makinelerinde eğitim algoritması standart Boltzmann makinelerinin eğitim algoritmasıyla aynıdır. Ancak ağların yapısal farklılıklarından ötürü algoritma uygulamada farklılıklar göstermektedir. Kısıtlı Boltzmann Makinelerine, Boltzmann Makinelerinde kullanılan eğitim algoritmaları birçok farklı yöntemle adapte edilebilir ancak bu çalışma kapsamında kullanılan ve en bilinen yöntem aşağıdaki gibidir:

1. Eğitim veri seti içerisinde bir veri noktası alınır.
2. Bu noktanın değerleri görünür katmana durumlar olarak atanır.
3. Daha sonra yukarıdaki bağıntı kullanılarak gizli katmanın durumları hesaplanır.
4. Aynı bağıntı gizli katman giriş katmanymış gibi değerlendirilerek kullanılır ve gizli katmanın değerlerinden görünür katmanın değerleri hesaplanır.
5. Bu güncelleme işlemine sistem dengeleninceye kadar devam edilir. $\lim (x) \rightarrow \infty$
6. Sistem dengelendikten sonra (yani iki ardışık iterasyon arasında sistemdeki birimlerin durumları arasındaki fark 0' ya yaklaşırken) aşağıdaki bağıntı ile birimler arası ağırlıklar güncellenir.

$$\Delta w_{ij} \propto \langle s_i s_j \rangle_{Q^0} - \langle s_i s_j \rangle_{Q^\infty} \quad (3-6)$$

Bu denklemde $\langle s_i s_j \rangle_{Q^0}$, $s_i s_j$ ikilisinin, görünür katmana veri uygulandıktan ve daha sonra gizli katmandan görünür katmandaki veri yeniden üretildikten sonra aldığı değerdir. Bu iteratif işleme **Gibbs Örnekleme**, üretilen bu veriye ise **rekonstrüksiyon** denir. $\langle s_i s_j \rangle_{Q^\infty}$ ise sonsuz sayıda Gibbs örneklemesinden sonra $s_i s_j$ ikilisinin beklenen değeridir.

Fakat bu öğrenme kuralı termal dengeye ulaşmanın çok uzun sürmesi ve değerinin oluşturduğu gürültünün yaklaşım gradyanını bozması sebebi ile iyi çalışmamaktadır. Hinton (Hinton, Training products of experts by minimizing contrastive divergence, 2002)³⁰ göstermiştir ki || ve || arasındaki farkı

³⁰ Hinton, G. E. (2002). Training products of experts by minimizing contrastive divergence. Neural Computing vol. 14, no. 8 , 1771–1800.

küçültmek algoritmayı çok daha efektif hale getirmektedir. Buradan yola çıkılarak algoritmanın bağıntısı

$$\Delta w_{ij} \propto \langle s_i s_j \rangle_{Q^0} - \langle s_i s_j \rangle_{Q^1} \quad (3-7)$$

Haline getirilmiştir. Bu eğitim algoritmasına Karşılaştırmalı İraksama (Contrastive Divergence) denir.

3.6.2 Karşılaştırmalı İraksama (Contrastive Divergence) Eğitim Metodu

Karşılaştırmalı iraksama eğitim metodu 2002 yılında G.E. Hinton tarafından önerilmiş (Hinton, Training products of experts by minimizing contrastive divergence, 2002) ve Kısıtlı Boltzmann Makineleri ile uygulanan, eğitim sırasında problemin çözümüne maksimum yaklaşım metodunun efektifliğini arttıran bir hedef fonksiyonudur. Kısıtlı Boltzmann Makineleri uygulamalarında Gibbs örneklemeleri ile birlikte bağlantı ağırlıklarının güncellenmesini sağlayarak, yapay sinir ağının eğitimini gerçekleştirir.

Kısıtlı iraksama sırasında, veri kümesi içerisinde bulunan her bir veri noktası için nispeten küçük bir sayıda (bu çalışma kapsamındaki prototip uygulamada örnekleme sayısı n , $5 < n < 10$ aralığında test edilmiş ve başarılı sonuçlar tespit edilmiştir.) Gibbs örneklemesi gerçekleştirilir. Daha sonra birimler arasındaki bağlantı ağırlıkları aşağıdaki formül ile güncellenir.

$$w_{ij} = w_{ij} + \eta(\langle v_i^0 h_j^0 \rangle - \langle v_i^n h_j^n \rangle) \quad (3-8)$$

Bu formül üzerinden değişkenleri tekrar değerlendirirsek; W_{ij} bağlantı ağırlığının değeri, η öğrenme katsayısı, $\langle v_i^0 h_j^0 \rangle$ karşılaştırmalı iraksama pozitif değeri, $\langle v_i^n h_j^n \rangle$ karşılaştırmalı iraksama negatif değeridir. Karşılaştırmalı iraksama pozitif değeri eğitim kümesi içindeki her bir veri noktası için bir kez Gibbs örneklemesi yapıldıktan sonra, görünür ve gizli katmandaki her bir birim için birbirine bağlı birimlerin çarpımlarının toplamıdır. Karşılaştırmalı iraksama negatif değeri ise n kez Gibbs örneklemesi yapıldıktan sonra birimlerin çarpımlarının toplamının değeridir.

3.6.3 Derin Öğrenme Ağları (Deep Belief Networks)

Derin öğrenme ağları birden çok olasılıksal gizli katmandan oluşan olasılık üretme modelleridir. İlk iki katman aslında bir Kısıtlı Boltzmann Makinesidir. Bir görünür ve bir gizli katmandan oluşur. Gizli katmanlardaki birimler genellikle ikili değerler

alır. Prototip uygulamada da gizli katmanlarda ikilik değerler kullanılmıştır. Yani katmanlardaki birimlerin durumları 0 veya 1 olabilir. Ancak Kısıtlı Boltzmann Makinesi sistemleri sürekli değerlerle de çalıştırıldığında başarılı sonuçlar elde edebilmektedirler. Bu gizli katmanlara özellik belirleyiciler (feature detectors) da denir. Özetle DB ağları birbirine ardışık olarak bağlı, birinin çıkış verileri sonrakini giriş verileri olan Kısıtlı Boltzmann Makineleri olarak da düşünülebilir. Derin öğrenme ağlarının en önemli iki özelliği:

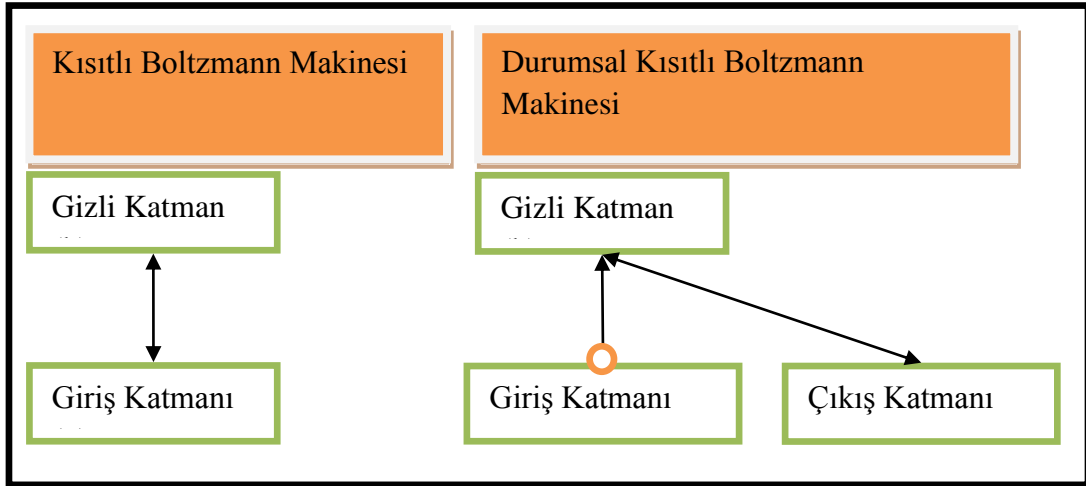
1. Eğitim katmanlarda ardışık olarak gerçekleşir. Yani birinci Kısıtlı Boltzmann Makinesi eğitildikten sonra, eğitim verisinin bu Kısıtlı Boltzmann Makinesinin gizli katmanında oluşturduğu çıkış vektörü sonraki Kısıtlı Boltzmann Makinesine eğitim verisi olarak verilir ve sonraki katmanlar içinde aynı kural devam eder.
2. Rekonstrüksiyon fazında da en son katmanda bulunan son çıkış vektörü kullanılarak son Kısıtlı Boltzmann Makinesinden ilk Kısıtlı Boltzmann Makinesine doğru veri akışı sağlanır ve ilk Kısıtlı Boltzmann Makinesinin görünür katmanında rekonstrüksiyon vektörü gözlemlenir.

Bu derin öğrenme ağlarının eğitiminde her Kısıtlı Boltzmann Makinesi için karşılaştırmalı ıraksama uygulandıktan ve Kısıtlı Boltzmann Makineleri termal dengeye ulaştıktan sonra, klasik geri yayılım algoritması kullanılarak daha da verimli sonuçlar elde edilebildiği bilinmektedir (Hinton & Salakhutdinov, Reducing the dimensionality of data with neural networks, 2006)³¹. Ancak bu optimizasyon prototip uygulama kapsamında geliştirilmemiştir.

3.6.4 Durumsal Kısıtlı Boltzmann Makineleri (Conditional Restricted Boltzmann Machines)

Durumsal Kısıtlı Boltzmann Makineleri sınıflandırma, kaotik zaman serisi tahmini, ses ve görüntü tanımlama gibi pek çok alanda literatürde yer edinmiş temel uygulama ve algoritmaları Kısıtlı Boltzmann Makinelerine çok benzeyen düzgün doğrusal olmayan veri analiz ve modelleme sistemleridir. Kısıtlı Boltzmann Makinelerinden farklı olarak bir gizli katman, bir giriş katmanı birde çıkış katmanı barındırır. Uygun problemlerde Durumsal Kısıtlı Boltzmann Makineleri üzerinde karşılaştırmalı ıraksama algoritmasının daha efektif çalıştığı gözlemlenmiştir. (Hinton, Training products of experts by minimizing contrastive divergence, 2002)

³¹ Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313 , 504-507.



Şekil 3.6 Kısıtlı ve Durumsal Boltzmann Makinelerinin Katman Yapıları

Durumsal Kısıtlı Boltzmann Makineleri sistemlerinin temel farkı karşılaştırmalı ırsama eğitim algoritması uygulanırken gözlemlenir. Karşılaştırmalı ırsama pozitif ve negatif değerleri hesaplanırken giriş katmanı görünür katman olarak değerlendirilir ve hesaba katılır. Ancak çıkış katmanı karşılaştırmalı ırsama negatif hesaplanırken hesaplamaya katılır. Böylece sistem girişin olasılık dağılımını modellemek yerine, giriş ile çıkış arasındaki ilişkinin olasılık dağılımını modeller.

Durumsal Kısıtlı Boltzmann Makineleri ağlarının diğer bir önemli özelliği ise kendi başlarına veya farklı Boltzmann Makineleri ağları ile derin öğrenme ağları oluşturabilirler. (Hinton, Osindero, & Teh, A fast learning algorithm for deep belief nets, 2006)³²

³² Teh, Y. W., & Hinton, G. E. (2000). Rate-coded Restricted Boltzmann Machines for Face Recognition.

4 PROTOTİP UYGULAMA

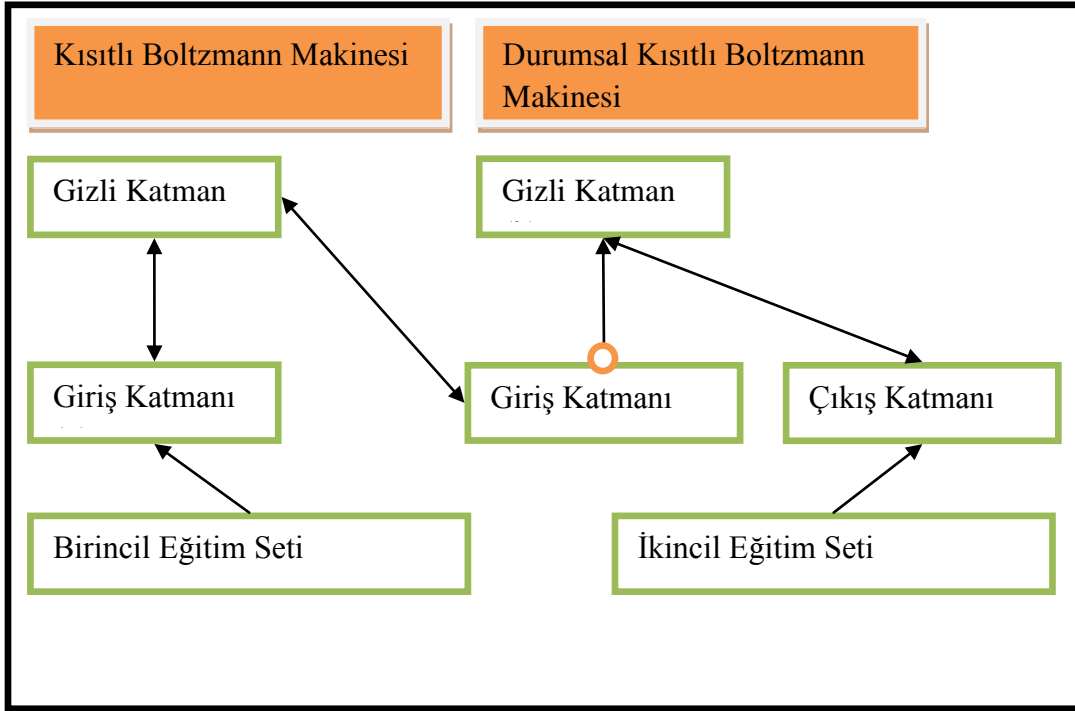
Bu çalışmada öne sürülen hipotez, Kısıtlı Boltzmann Makineleri yapay sinir ağı algoritmaları kullanılarak, resimlere ait görüntülerden, eserlerin sanatçılarının tahmin edilebileceğidir. Bu hipotez, çalışma dahilinde geliştirilen prototip uygulama ve bu uygulama üzerinde yapılan deneylerden elde edilen sonuçlar ile desteklenmiştir. Bu bölümde geliştirilen prototip uygulamadan bahsedilecektir.

4.1 GELİŞTİRME ORTAMI

Prototip uygulama Java programlama dili kullanılarak, Sun Netbeans entegre geliştirme ortamında geliştirilmiştir. Java programlama dili, akademik çevrelerde yaygın kullanımı, açık kaynak kodlu yazılım geliştirmeyi teşvik etmesi, nesneye yönelik yapısı ile problemleri modellemeyi kolaylaştırması, ara yüz programlama için kütüphaneler sunması, ücretsiz olması, farklı platformlarda ve işletim sistemlerinde çalışabilmesi gibi nedenlerden dolayı tercih edilmiştir.

4.2 KISITLI VE DURUMSAL BOLTZMANN MAKİNELERİ ALGORİTMALARININ UYGULAMASI

Prototipte geliştirilen yapay sinir ağı uygulaması bir Kısıtlı Boltzmann Makinesi katmanı ve buna bağlı bir Durumsal Boltzmann makinesi katmanından oluşmuş bileşik bir derin öğrenme ağıdır.



Şekil 4.1 Prototip uygulamada Kısıtlı ve Durumsal Boltzmann Makinelerinin birleştirilmesi

Sistemde aynı görüntülerden oluşturulmuş, iki farklı eğitim kümesi bulunmaktadır. Birinci kümede çalışmanın kapsamında incelenen sanatçılara ait (Vincent Van Gogh, Salvador Dali ve Pablo Picasso) bir grup resme ait görüntüler karışık olarak bulunmakta, ikinci kümede ise aynı görüntüler dizinler altında sınıflandırılmış olarak bulunmaktadır. Birinci küme sistemin farklı doku ve biçimleri tanımayı, ikinci küme ise sistemin ressamı tanımayı öğrenmek için kullandığı eğitim verileri olarak düşünülebilir.

Birinci ve ikinci küme aynı görüntüleri yani aynı verileri içermektedir. Birinci kümede görüntüler sınıflandırılmamış, fakat ikinci kümede sanatçı bazında sınıflandırılmış olarak bulunmaktadır. Ancak prototip uygulama ile yapılan deneyler göstermektedir ki bu iki kümenin aynı verilere sahip olması da zorunlu değildir. Birinci küme birbirinden kompozisyon, biçim, doku ve sanatçı olarak olabildiğince farklı ve homojen dağılıma sahip görüntüler barındırdığı sürece, ikinci küme göre daha az sayıda görüntü içerebilir. Bu durum sistemin eğitim performansını hız olarak iyileştirmekte buna karşın genel tanıma başarımını küçük bir oranda düşürmektedir.

Birinci kümedeki veriler kullanılarak Kısıtlı Boltzmann Makinesi eğitilir. Prototip uygulamada kullanılan Kısıtlı Boltzmann Makinesi bir görünür ve bir gizli katmandan oluşan, görünür katmanında 16382 (128x128) birim, gizli katmanında ise 256 birim bulunan bir yapay sinir ağıdır. Birincil kümedeki veriler ile Kısıtlı Boltzmann Makinesinin eğitimi tamamlandığında makine buradaki resimler için 256

değerli özellik belirleyici vektörlerini oluşturmuş ve bu vektörlerden tekrar bu görüntüleri oluşturabilecek düzeye gelmiştir.

Bu aşamadan sonra Durumsal Kısıtlı Boltzmann Makinesinin eğitimi başlatılır. Durumsal Kısıtlı Boltzmann Makinesinin eğitimi destekli eğitimidir. İkincil eğitim kümesindeki veriler sanatçılar bazında sınıflandırılmıştır. İkincil eğitim kümesindeki her bir veri yani bir sanatçıya ait resmin dijital görüntüsü, hangi sanatçıya ait olduğu bilgisi ile birlikte sisteme verilir. Öncelikle bu veri Kısıtlı Boltzmann Makinesi ağından geçirilir ve Kısıtlı Boltzmann Makinesi ağı bu veri için özellik vektörünü oluşturur. Daha sonra Durumsal Kısıtlı Boltzmann Makinesi ağı bu özellik vektörü ve sanatçı bilgisi kullanılarak, bu özellik vektörü için bu sanatçı bilgisini üretmesi yönünde eğitilir.

Durumsal Kısıtlı Boltzmann Makinesi ağının görünür katmanı Kısıtlı Boltzmann Makinesi ağının gizli katmanına bağlı olduğundan 256 birimden Durumsal Kısıtlı Boltzmann Makinesi ağının gizli katmanı ise 512 birimden oluşur. Durumsal Kısıtlı Boltzmann Makinesi ağının çıkış katmanı ise ikinci eğitim kümesindeki sınıflandırma klasörleri sayısı kadar dinamik olarak oluşturulur. Bu çalışmada 3 sanatçı incelendiğinde Durumsal Kısıtlı Boltzmann Makinelerinin çıkış katmanında 3 birim bulunmaktadır. Bu birimler ikilik değerler içerir. Sisteme girişi yapılan görüntülere ait sanatçı bilgisi Şekil 4.2 'deki gibi oluşturulur.

Görüntü boyutları, birinci ve ikinci katman özellik belirleyici vektör uzunlukları ve diğer katman parametreleri prototip uygulamanın geliştirilmesi sürecinde yapılan deneyler sonucu, sistemin kabul edilebilir sürelerde belirgin bir tanıma başarısını gösterebildiği, tespit edilebilen en uygun değerlerdir. Deneylere devam edilerek daha yüksek tanıma başarısını daha kısa eğitim sürelerinde gerçekleştirebilecek parametreler bulunabilir.

Görüntü	Vincent Gogh	Van Salvador Dali	Pablo Picasso
 <p>Vincent Van Gogh</p>	1	0	0
 <p>Salvador Dali</p>	0	1	0
 <p>Pablo Picasso</p>	0	0	1

Şekil 4.2 Sistemden beklenen çıkış verisi yapısı

4.3 PROTOTİP SİSTEMİN SÜREÇLERİ VE UYGULAMA

4.3.1 Ön Filtreleme

Prototip uygulama eğitim ve tahmin evresinde, eğitim dizinlerinde bulunan, İnternet üzerinde URL ile çağrılan veya test dizinlerinden çağrılan görüntülerin tamamına bir ön filtreleme işlemi uygular. Ön filtreleme görüntünün işlenmeden önce geçirdiği bir standartlaştırma aşaması olarak düşünülebilir. Yapılan benzer görüntü işleme çalışmalarında da farklı önfiltrleme işlemleri kullanılmaktadır. (Teh & Hinton, 2000)



Şekil 4.3 Hinton ve Teh'in yüz tanıma için yaptıkları önfiltreleme. a) Orijinal görüntü, b)Gözlerin belirlenmesi, c) Gözlere göre çevirme işlemi, d)Kırpma işlemi, e) Arka plan temizleme, f) Yoğunluk histogramı dengeleme

Prototip uygulamada kullanılabilmesi için bir görüntünün 256x256 piksel boyutlarında veya daha büyük olması gerekmektedir. Ayrıca görüntüler JPEG formatında, 8 bit renk derinliğine sahip olmalıdır. Görüntü sisteme girdiğinde ilk yapılan işlem kadrajlamadır. Sistemin sabit sayıda girişi yani Kısıtlı Boltzmann Makinesi ağının görünür katmanını belirli sayıda birimi olduğu için bu işlemin yapılması gerekmektedir. Dolayısı ile eni ile boyu arasında büyük oransal farklılıklar olan görüntüler sisteme girilmeden önceden karesel formlarda parçalanarak incelenmelidir. Otomatik kadrajlama işlemi sistemin eni ve boyundan hangisi daha küçükse, büyük olan parametreyi de küçük olan parametre ile eşitleyecek şekilde görüntüyü ortalayarak kırpar. Karesel oranlara kırpılmış olan resim, Kısıtlı Boltzmann Makinesi katmanının giriş sayısına göre boyutlandırılır. Görüntüler her zaman karesel olarak boyutlandırıldığından, Kısıtlı Boltzmann Makinesi giriş sayısı da tam köklenebilir bir sayı olmalıdır. Yani $\frac{\text{tam köklenebilir bir sayı}}{\text{tam sayı}} =$ tam sayı olmalıdır. Prototip uygulamada deneyler ve başarı ölçütleri için belirlenen varsayılan ölçüt 128x128 pikseldir. Kısıtlı Boltzmann Makinesi ağının giriş katmanında da 128x128 = 16384 birim bulunmaktadır. Bu işlemde sonra görüntünün piksel değerlerinden bir doku verisi vektörü hazırlanır. Görüntüdeki piksel değerleri (R,G,B) yani kırmızı, yeşil, mavi değerleri şeklindedir. Uygulamada kullanılan 8 bitlik renk derinliğine sahip görüntülerde bu değerler 0-255 aralığındadır. Piksel üzerindeki bu renk bilgisi kullanılarak her piksel için aşağıdaki siyah beyaz doku değeri () denklem (4-1) deki gibi elde edilir.

(4-1)

Böylece görüntüdeki her piksel için -1 ile +1 arasında bir siyah beyaz değer elde edilmiş olur. Görüntüdeki her piksel için bu işlem tamamlandıktan sonra bu değerlerden bir vektör oluşturulur. Son olarak bu vektör üzerinde bir

normalizasyon işlemi gerçekleştirilir. Bu normalizasyon işlemi ile hedeflenen, görüntülerin zıtlık, parlaklık ve ışıklandırma farklılıklarından dolayı barındırdıkları gürültüyü azaltmaktır. Normalizasyon işlemi aşağıdaki (4-2) bağıntısı ile gerçekleştirilir:

$$(4-2)$$

Bu işleme yoğunluk histogramı dengeleme de denir ve şekil b de 2000 yılında Hinton ve Teh'in Boltzmann Makineleri ile geliştirdiği insan yüzü tanıma uygulamasında bazı ek filtreleme işlemleri ile birlikte nasıl gerçekleştirdikleri gösterilmiştir. Histogram dengeleme işleminden sonra görüntüler sisteme girmeye hazırdır.

4.3.2 Eğitim Süreci ve Eğitim Kümelerinin Hazırlanması

Prototip uygulama Van Gogh, Pablo Picasso ve Salvador Dali'ye ait eserlerin İnternet üzerinden elde edilen nispeten düşük çözünürlüklü görüntülerinden oluşturulan bir veri tabanı ile test edilmiştir. Ancak prototip η sayıda ($0 < \eta < \infty$) sayıda farklı sanatçıyı tanıyabilecek şekilde geliştirilmiştir. Fakat prototip ile yapılan deneylerde sanatçı sayısı arttıkça Kısıtlı ve Durumsal Boltzmann makineleri sistemlerinin diğer yapay sinir ağı sistemlerinde de olduğu gibi gerektirdiği yapay sinir hücresi sayısı logaritmik olarak artmaktadır.

Prototip uygulama içerisinde birincil ve ikincil görüntüler için iki dizin bulunmaktadır. Programın çalıştığı kök dizinin altında "images" -> "train01" birincil eğitim kümesi için varsayılan dizin, "images" -> "train02" ikinci eğitim kümesi için varsayılan dizindir.

Eğitim verileri hazırlandıktan sonra yapay sinir ağının ilk katmanı Kısıtlı Boltzmann Makinesi özellik belirleme için eğitilir. Kısıtlı Boltzmann Makinesi eğitiminde prototip uygulama üzerinden Kısıtlı Boltzmann Makinesine ait görünür ve gizli katmandaki birim sayıları, öğrenme katsayısı, sistemin momentumu, birincil eğitim dizini, eğitimin sonlanması için gerekli minimum hata oranı ve eğitim iterasyon sayıları gibi parametreler değiştirilebilir. Burada eğitim iterasyon sayısı "Max. Learn Epoch" karşılaştırmalı ıraksama algoritmasının ardışık olarak sisteme kaç defa uygulanacağını belirler. "Min. Error Rate" minimum hata oranı ise sistemin belirli bir hata değerinin altına düştüğünde eğitimin, henüz iterasyon sayısı bitmemiş bile olsa durdurulmasını sağlar.

Önceki bölümlerde ve karşılaştırmalı ıraksama algoritmasında anlatıldığı gibi Kısıtlı Boltzmann Makinesi sisteminin giriş katmanına veri uygulandığında Kısıtlı

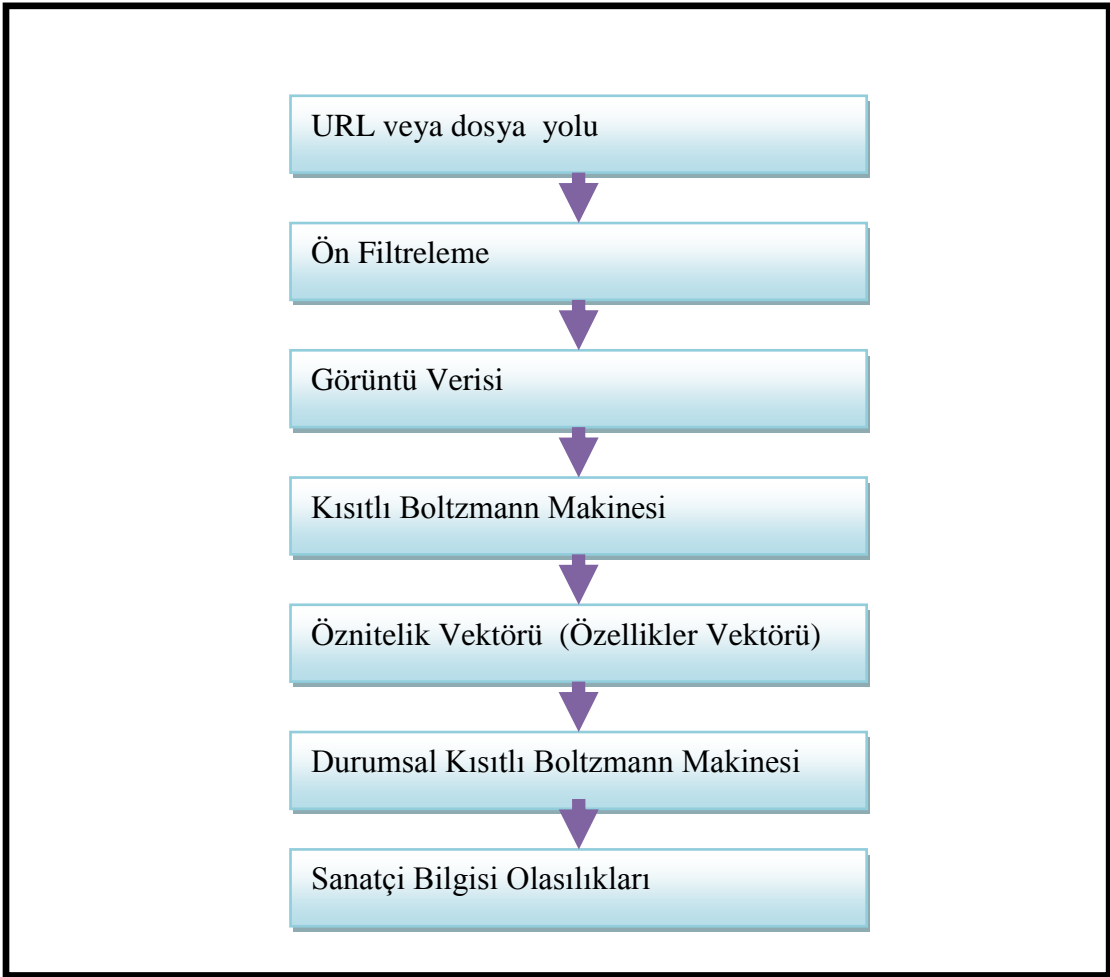
Boltzmann Makinesi bu veri için bir özellik vektörü belirler. Daha sonra da sistem içerisinde tersine çalışarak bu özellik vektöründen verinin rekonstrüksiyonunu oluşturur. Prototip uygulamada hata (4-3) ifadesi ile hesaplanmaktadır.

$$(4-3)$$

Uygulamaya girilen eğitim iterasyon sayısına veya minimum hata oranına ulaşıldığında birinci katmanını eğitimi tamamlanır.

İkinci katmanın eğitiminde ise ikincil dizin kullanılır. Bu dizindeki alt dizin yapısına göre etiketlenen veriler, Durumsal Kısıtlı Boltzmann makinesi katmanına, Kısıtlı Boltzmann makinesi çıktısı (veri) ve sanatçı olarak verilir. Özetle bu katmandaki her bir veri için önceki aşamada eğitilen Kısıtlı Boltzmann makinesi katmanı tarafından bir özellik vektörü bulunur. Durumsal Kısıtlı Boltzmann makinesi ise bu özellik vektörüne bakarak verinin hangi sanatçıya ait bir resmin görüntüsü olduğunu modeller. Uygulama ile sadece sanatçı bazında değil, dönem, kategori form bazında da sınıflandırmalar yapılabilir. Prototip ile yaptığımız deneylerde sistemin, el yazısı ve geometrik şekilleri sınıflandırmada yaklaşık %90 başarılı olduğu tespit edilmiş ve bu başarı sistemin geliştirilmesine devam edilmesi gerekliliğini ortaya koymuştur. Durumsal Kısıtlı Boltzmann makinesi katmanında da hata aynen Kısıtlı Boltzmann makinesi katmanında olduğu gibi hesaplanır ve algoritmik parametreler birebirdir.

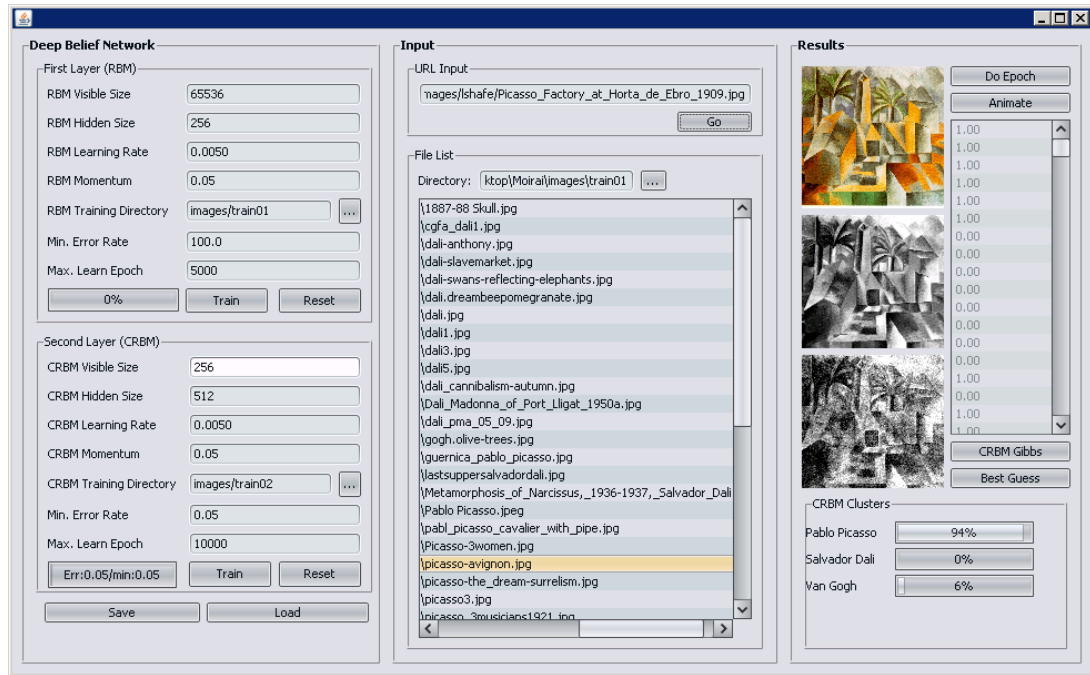
4.3.3 Ressamları Tanıma



Şekil 4.4 Sanatçıları tanıma işlemi sırasında uygulamanın akışı

Prototip uygulamanın görüntü tanıma sistemi Şekil 4.4'deki gibidir. Sisteme dosya yolu veya adresi(URL) girilen bir görüntü dosyası olduğu gibi okunur. Daha sonra önfiltrleme işlemleri gerçekleştirilerek sisteme girilebilecek hale getirilir. Bu aşama uygulama ara yüzünde önfiltrleme işlemi gerçekleştirilmiş ve yeniden boyutlandırılmış ham görüntü gösterilir. Düzenlenmiş görüntü Kısıtlı Boltzmann Makinesi katmanına uygulanır. Kısıtlı Boltzmann Makinesi katmanının rekonstrüksiyonu da programın ara yüzünde görüntülenir. Kısıtlı Boltzmann Makinesi katmanı bu veri için bir öznitelik vektörü oluşturur ve bu vektör Durumsal Kısıtlı Boltzmann Makinesi katmanının girişine uygulanır. Durumsal Kısıtlı Boltzmann Makinesi katmanı da uygulamada çalışılan üç sanatçı için girilen verinin hangi sanatçıya ait olabileceğinin olasılıklarını bulur ve bu olasılıklar ara yüzde gösterilir.

4.3.4 Programın Kullanımı ve Arayüz



Şekil 4.5 Prototip Uygulamanın Kullanıcı Arayüzü

Prototip uygulama ekran görüntüsünde de görüldüğü gibi 3 temel bölümden oluşur. Birinci bölüm “Deep Belief Network”, sistemin katmanları ve eğitim ile ilgili işlemleri barındırır. İkinci bölüm “Input” sisteme görüntü verisi girişi yapılmasını sağlar. Üçüncü bölüm ise sisteme giriş yapıldıktan sonra sistemin görüntü ile ilgili yaptığı analiz sonuçlarının gösterildiği bölümdür.

4.3.5 Yapay Sinir Ağı Katmanları, Parametreler ve Eğitim

Birinci Katman “First Layer (RBM)”

Bu bölümde sistemin birinci Kısıtlı Boltzmann Makinesi katmanı ile ilgili yapısal parametreler ve eğitim parametreleri ayarlanır.

“RBM Visible Size”, Kısıtlı Boltzmann Makinesi ağı görünür katman birim sayısıdır.

“RBM Hidden Size”, Kısıtlı Boltzmann Makinesi ağı saklı katman birim sayısıdır.

“RBM Learning Rate”, Kısıtlı Boltzmann Makinesi ağı öğrenme katsayısı değeridir.

“RBM Momentum”, Kısıtlı Boltzmann Makinesi ağı öğrenme momentumu değeridir.

“RBM Training Directory”, Kısıtlı Boltzmann Makinesi ağının eğitim için kullanacağı görüntülerin bulunduğu dizinin dosya yoludur.

“Min. Error Rate”, Kısıtlı Boltzmann Makinesi ağının eğitimi durdurması için ulaşması gereken minimum hata değeridir.

“Max. Learn Epoch”, Kısıtlı Boltzmann Makinesi ağının her koşulda eğitimi durdurması gereken eğitim iterasyonu adım sayısıdır.

“Train”, Kısıtlı Boltzmann Makinesi ağının eğitime başlamasını tetikleyen butondur.

“Reset”, Kısıtlı Boltzmann Makinesi ağının hafızasını yani tüm eğitim hafızasını sıfırlar.

The image shows a software interface for configuring a Deep Belief Network. It is divided into two main sections: 'First Layer (RBM)' and 'Second Layer (CRBM)'. Each section contains several input fields for parameters like size, learning rate, momentum, and training directory, along with buttons for 'Train' and 'Reset'. A progress indicator shows '0%' for the first layer. At the bottom, there are 'Save' and 'Load' buttons.

Layer	Parameter	Value
First Layer (RBM)	RBM Visible Size	65536
	RBM Hidden Size	256
	RBM Learning Rate	0.0050
	RBM Momentum	0.05
	RBM Training Directory	images/train01
	Min. Error Rate	100.0
	Max. Learn Epoch	5000
	Progress	0%
Second Layer (CRBM)	CRBM Visible Size	256
	CRBM Hidden Size	512
	CRBM Learning Rate	0.0050
	CRBM Momentum	0.05
	CRBM Training Directory	images/train02
	Min. Error Rate	0.05
	Max. Learn Epoch	10000
	Status	Err:0.05/min:0.05

Şekil 4.6 Prototip Uygulama Birinci Katman Ayarları Arayüzü

İkinci Katman “Second Layer (CRBM)”

“CRBM Visible Size”, Durumsal Kısıtlı Boltzmann Makinesi ağı görünür katman birim sayısıdır. Değiştirilemez. Yapısal olarak birinci Kısıtlı Boltzmann Makinesi katmanının saklı katman birim sayısı değerini alır.

“CRBM Hidden Size”, Durumsal Kısıtlı Boltzmann Makinesi ağı saklı katman birim sayısıdır.

“CRBM Learning Rate”, Durumsal Kısıtlı Boltzmann Makinesi ağı öğrenme katsayısı değeridir.

“CRBM Momentum”, Durumsal Kısıtlı Boltzmann Makinesi ağı öğrenme momentumu değeridir.

“CRBM Training Directory”, Durumsal Kısıtlı Boltzmann Makinesi ağının eğitim için kullanacağı görüntülerin bulunduğu dizinin dosya yoludur.

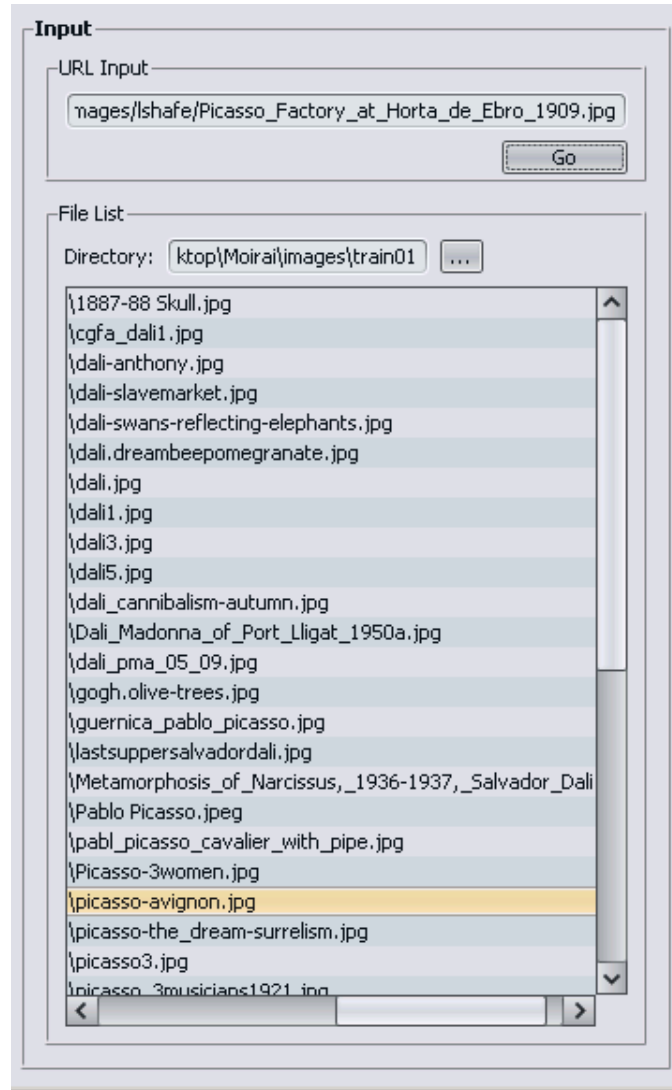
“Min. Error Rate”, Durumsal Kısıtlı Boltzmann Makinesi ağının eğitimi durdurması için ulaşması gereken minimum hata değeridir.

“Max. Learn Epoch”, Durumsal Kısıtlı Boltzmann Makinesi ağının her koşulda eğitimi durdurması gereken eğitim iterasyonu adım sayısıdır.

“Train”, Durumsal Kısıtlı Boltzmann Makinesi ağının eğitime başlamasını tetikleyen butondur.

“Reset”, Durumsal Kısıtlı Boltzmann Makinesi ağının hafızasını yani tüm eğitim hafızasını sıfırlar.

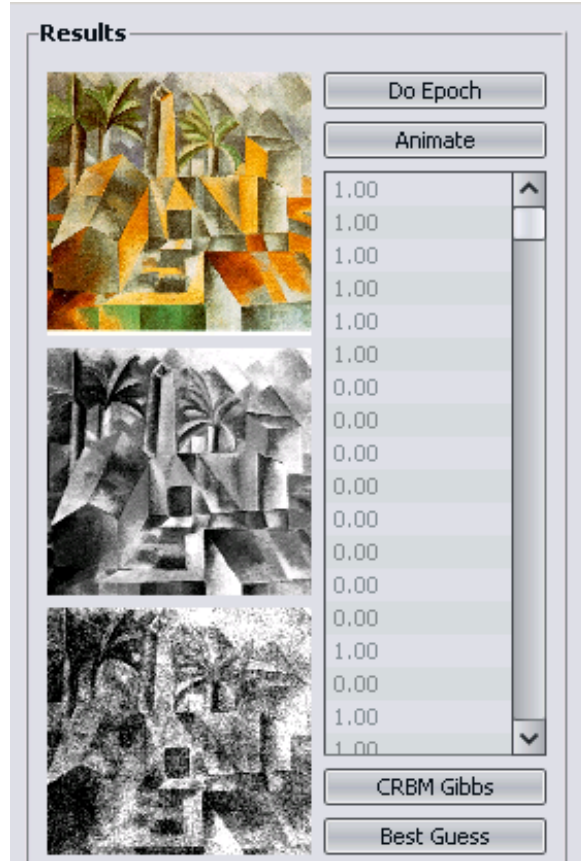
Ayrıca Yükle(“Load”) ve Kaydet(“Save”) komutları ile eğitilmiş derin öğrenme ağı sistemi kaydedilip daha sonra tekrar kullanılabilir.



Şekil 4.7 Prototip Uygulama İkinci Katman Ayarları Arayüzü

4.3.6 Giriş ve Analiz


Uygulamaya görüntü verisi girişi iki şekilde yapılabilir. Eğer işlenmek istenen görüntü İnternet üzerinde bir konumda ise bu görüntüye ait dosyanın İnternet adresi “URL Input” metin kutusuna girilir ve “Go” butonuna basılır. Sistem sonuç bölümünde görüntüyü ve analiz sonuçlarını gösterinceye kadar beklenir. İkinci bir yöntem ise “File List” paneli altındaki “Directory:” metin kutusuna yerel bir dizin yolu girilir veya “...” butonuna basılarak görsel olarak dosya sisteminde seçilir. Daha sonra sistem aynı paneldeki liste yapısında bu dizin altında bulunan ve işleyebileceği uygun biçemdeki dosyaları listeler. Bu listedeki dosyalardan biri seçildiğinde analiz işlemi otomatik olarak başlar.



Şekil 4.8 Prototip Uygulama Veri Giriş ve Birinci Katman Sonuç Arayüzü

4.3.7 Analiz Sonuçları

“Results” panelindeki 3 görsel sırası ile orijinal görüntünün yeniden boyutlandırılmış görüntüsü, orijinal görüntünün önfiltreleme işleminden geçmiş ve siyah beyaz hale getirilmiş görüntüsü ve Kısıtlı Boltzmann Makinesi katmanının rekonstrüksiyonu (başka bir deyişle düşüncesi) dur. Görsellerin hemen yanında bulunan değerler listesi Kısıtlı Boltzmann Makinesi katmanının ürettiği öznitelikler vektörüdür. “CRBM Clusters” panelinde bulunan yüzde göstergeleri ise sistemin verilen görselin hangi ressamı ait olabileceği konusunda yaptığı olasılık analizinin sonuçlarıdır.



Şekil 4.9 Prototip Uygulama Analiz Sonuçları Arayüzü

4.4 MAKİNANIN EĞİTİMİ VE İŞLEM SONUÇLARI

4.4.1 Eğitim ve Eğitim Kümesi

Prototip uygulamanın Kısıtlı ve Durumsal Boltzmann makinesi katmanı Ek 1’de tablo halinde verilen sayısal görüntüler ile eğitilmiştir. Durumsal Boltzmann makinesi ağının eğitiminde resimlerle birlikte hangi sanatçıya ait oldukları eğitim verisi olarak kullanılmıştır.

Eğitim kümesi seçilirken sanatçıların olgunluk dönemlerinde ürettikleri nispeten iyi bilinen eserleri kullanılmıştır. Eğitim kümesinde eser sayısı artırıldıkça sistemin tanıma başarısının, çalışmanın önceki bölümlerinde tüm yapay sinir ağları için belirtildiği gibi doğal olarak arttığı ancak eğitim süreçlerinin logaritmik olarak performansının düştüğü ve çok daha uzun sürdüğü tespit edilmiştir. Bu yüzden eğitim kümesi, uygulama kabul edilebilir başarı değerleri sergileyinceye kadar genişletilmiştir. Ancak daha geniş bir eğitim kümesi ile uygulamanın daha yüksek başarı değerleri sergileyebileceği söylenebilir.

4.4.2 Deney Kümesi

Test veri kümesi, popüler arama motorlarından sanatçıların isimleri giriş yapılarak aratılan resimlerine ait görüntülerden oluşturulmuştur. Arama sonuçlarının başından başlanarak her sanatçı için 30 adet görüntü seçilmiştir. Bu görüntülerden 20 tanesine Adobe Photoshop yazılımı kullanılarak %12.5 Gauss gürültüsü eklenmiştir. Ayrıca görüntüler her kenardan %20 kesilerek yeniden kadrajlandırılmıştır ve farklılaştırılmıştır. 30 çevrimiçi ve 20 yapay gürültü eklenmiş toplam 50 görüntü ile uygulama test edilmiştir. Yapay gürültü eklenmesinin sebebi görüntüler üzerindeki gürültü bileşeni ölçülebilir olmadığından, sistemin belirli bir gürültü bileşenine kesinlikle sahip görüntüler ile test edilmesini sağlamaktır. Eklenen gürültünün uygulamanın başarısını değiştirmedeği gözlemlenmiştir.

Yapılan deneyler sonucu uygulamanın Pablo Picasso’ya ait eserlerin görüntülerini %62.5, Salvador Dali’ye ait eserlerin görüntülerini %76, Van Gogh’a ait eserlerin

görüntülerini %60 başarı ile tanıyabildiği tespit edilmiştir. Tüm deney kümesi için uygulamanın ürettiği sonuçlar Ek 2 de bulunmaktadır.

Uygulamanın ürettiği bu sonucun sanatçılar bazında farklılığı, sanatçıların biçimsel yorumlarının ne kadar küçük bir görüntü parçasından anlaşılabilir olduğu ile bağdaştırılabilir. Bir diğer deyişle Van Gogh'un eserlerinde sanatçının yorumunda fırça darbeleri de belirleyici iken, Salvador Dali'nin eserlerinde yorum tüm kompozisyona hacimsel ve biçimsel olarak dağılmış durumdadır. Dolayısı ile Salvador Dali'yi resmin geneline bakarak tanımak göreceli olarak daha kolay iken Van Gogh'un resimlerinde fırça darbelerine bakmak daha anlamlı olacaktır. Buradan yola çıkarak prototip uygulama ve geliştirilen uygulama ile ilgili olarak şöyle bir varsayım yapılabilir. Sanatçının yorumu resmin geneline ne kadar homojen olarak dağılmış ise ve bu durum farklı eserlerinde ne kadar tutarlı ise uygulama o sanatçıyı tanımada o ölçüde başarılı olacaktır. Bu durumun temel sebebi ise uygulamanın girişinin performans kısıtlarından dolayı küçültülmüş olmasıdır. Van Gogh'un eserleri 128x128 piksel boyutlarına küçültüldüklerinde fırça darbelerinin kattığı yorumu dolayısı ile sanatçının yorumunu, Salvador Dali'nin eserlerine göre daha fazla kaybetmektedirler. Daha güçlü donanımlar ve algoritma üzerinde yapılacak iyileştirmeler ile daha büyük görüntüler sisteme giriş olarak verilirse, bu başarı farkının azalacağı ve genel başarının artacağı düşünülmektedir.



% 72 Pablo Picasso
% 67 Salvador Dali
% 59 Van Gogh

Şekil 4.10 Picasso deney örneği

Şekil 4.10'daki gibi bir sonuç uygulamanın görüntünün ek yüksek olasılıkla Pablo Picasso ile ilişkilendirebileceğini göstermektedir. Bu görüntü için yapılan analiz başarılı kabul edilmektedir.



% 38 Pablo Picasso
% 87 Salvador Dali
% 50 Van Gogh

Şekil 4.11 Van Gogh deney örneği

Şekil 4.11'deki gibi bir sonuç başarısız bir sonuçtur. Uygulama gökyüzü ve ufuk kompozisyonu, nesnel arasındaki büyüklük küçüklük ilişkileri yönünden görüntünün en yüksek olasılıkla Salvador Dali'ye ait olabileceğini göstermektedir. Ancak görüntüdeki eserin Vincent Van Gogh'a ait olduğu bilinmektedir. Şekil 4.10 ve Şekil 4.11 deki görüntüler yeniden kadrajlanmış ve gürültü eklenmiş görüntülerdir.

4.4.3 Deney Sonuçları ve Başarım Yorumu

Gerçekleştirilen deneyler uygulamanın Pablo Picasso'ya ait eserlerin görüntülerini tanımada %62.5, Salvador Dali'ye ait eserlerin görüntülerini tanımada %76, Van Gogh'a ait eserlerin görüntülerini tanımada %60 başarılı olduğunu göstermiştir.

İlk bakışta birbirlerinden oldukça farklı olan bu sanatçıların eserlerinin bu başarı oranları ile tanınması nispeten düşük görünebilir. Ancak bu noktada uygulamanın bir prototip olduğu, başarı oranlarının %60'ın üzerinde olduğu ve bu tarz görüntü tanıma uygulamalarının, hiç bir zaman %100 başarı elde edemediği ve insanların zaman zaman yanılabilirliği gibi yanılabilir kadar zeki sistemler olduğu unutulmamalıdır.

Sistemin başarılı analizler yapamadığı bazı sonuçlarda ise neden başarısız olduğuna dair yorumlar yapılabilir.



% 77 Pablo Picasso
% 86 Salvador Dali
% 43 Van Gogh

Şekil 4.12 Van Gogh deney örneği

Örneğin Şekil 4.12’de görülen deney örneğinde, sistem Vincent Van Gogh’un “Yatak Odası” tablosunu %86 Salvador Dali ve %77 Pablo Picasso olarak yanlış yorumlamıştır. Ancak bu eserin, Dali’nin ufuk çizgisi ve mekânsal boşluk kompozisyonlamasını ve Picasso’nun kübist çizgilerini barındırdığı görülebilir. Bu sonuç, uygulamada daha fazla sinir ağı katmanı kullanılarak, algoritmanın bu tarz kompozisyon benzerliği gösteren eserlerde daha yüksek başarı sağlayabileceğini de göstermektedir.



% 88 Pablo Picasso
% 27 Salvador Dali
% 66 Van Gogh

Şekil 4.13 Picasso deney örneği

Şekil 4.13’da görülen analiz ise doğru bir analizdir. Sistem görüntüyü %88 maksimum değeri ile Picasso ile eşleştirmiş ve doğru bir yorum yapmıştır. Ancak diğer sanatçılara bakıldığında sistem görüntüyü %27 Dali ve %66 Van Gogh ile benzeştirmiştir. Bu görüntüde de Dali’nin kompozisyonlarında bulunan hacimsel dolgunluk ve Van Gogh’un portre kompozisyonlaması fark edilebilir.



% 56 Pablo Picasso
% 96 Salvador Dali
% 46 Van Gogh

Şekil 4.14 Dali deney örneği

Şekil 4.14’da görülen deney örneği de doğru bir analizdir ve şekil 1 ve şekil 2 için yapılan yorumların benzerleri yapılabilir. Bu görüntü Ek 1 ve Ek 2 de görüleceği üzere eğitim kümesinde de bulunmamaktadır. Ayrıca hem kırılmış, hem de üzerine yapay gürültü eklenmiştir. Buna rağmen sistem görüntüyü başarılı ve yüksek bir olasılıkla doğru sanatçı ile eşleştirmiştir.

4.5 SONRAKİ ADIMLAR

Bu tez çalışması kapsamında ve geliştirilen uygulamada zaman ve kaynak kısıtları nedeni ile geliştirilmesi düşünülen ancak geliştirilemeyen pek çok optimizasyon bulunmaktadır. Çalışmanın temel hedefi, kısıtlı Boltzmann makineleri ile geliştirilen bir uygulamanın, ressamın eserlerinin yüksek gürültü bileşenleri bulunduran görüntülerinden ressamı tanıyabileceğinin ortaya koyulması olduğundan tatmin edici sonuçlar alındıktan sonra çalışma tamamlanmıştır. Ancak yapay sinir ağlarının gelişimi ve literatür bu tarz projelerin optimizasyonunun yıllarca sürebileceğini, bilim adamları problemi ve sistemi tanıdıkça başarı oranlarının gittikçe yükseldiğini göstermektedir.

Uygulama üzerinde çok sayıda deney yapmak uygulamanın başarısını arttırmanın en kesin yoludur. Fakat performans kısıtları nedeni ile uygulama üzerinde başarıyı arttıracak düşünülen her deneyi gerçekleştirmek mümkün değildir. Bu nedenle algoritmaların uygulamasında ve hatta algoritmalarda performansı arttıracak yazılımsal iyileştirmeler yapılabilir. Örneğin Kısıtlı Boltzmann makineleri ile ekran bağdaştırıcı ve çok çekirdekli işlemci donanımları ile yapılan çalışmalar (McAfee, 2009), yazılım uyarlamaları ile sistemin çok daha büyük görüntüleri, çok daha hızlı şekilde işleyebileceğini göstermiştir.

Yine literatür fazla sayıda katmanı ve fazla sayıda sinir hücresi bulunan sistemlerin karmaşık problemleri çözmeye daha başarılı olduğunu göstermektedir. Biyolojik sistemlerde de canlıların sinir sistemleri karmaşıklaştıkça ve sinir hücresi sayısı arttıkça daha zeki oldukları gözlemlenmiştir. Performansı arttıracak yazılım geliştirmeleri ve yeterli donanım temin edilebilirse, sistem daha zeki bir sistem haline gelecektir ve bu da başarının artması anlamına gelmektedir.

Yapay sinir ağlarında da biyolojik zeki sistemlerde olduğu gibi eğitimin önemi kaçınılmazdır. Sistemin eğitileceği veri kümesinin, bu sistemi değerlendirebilecek sanatçılar ve uzmanlar tarafından seçilmesi ve bu eğitim kümesinin yapay sinir ağı ile çözülecek probleme göre olabildiğince geniş tutulması sistemin başarısını arttıracaktır. Başarıyı ölçecek deney kümesi içinde aynı sözler ifade edilebilir.

Geliştirilen sistemin yapısı İnternet ile daha etkileşimli ve çevrimiçi sistemlerle farklı uygulamalarda kullanılabileceğini göstermektedir. Örümcek olarak bilinen ve çevrimiçi içerikleri tarayarak sınıflandıran uygulamalar ile bütünleşik kullanımında bu uygulama görüntülerin, sanatçıların isimleri ile sınıflandırılmasını sağlayabilir. Çevrimiçi eğitimde, İnternet topluluklarında, çevrimiçi ve bilgisayar ortamında sanat ve tasarım alanlarında bulunan tüm içerik üzerinde geliştirilebilecek birçok uygulamada bu sistem otonom bir uzman sistem olarak kullanılabilir.

Bütün bu bahsedilen geliştirmeler, sistemin başarımını ve performansı dolayısı ile kullanılabilirliğini, kullanım alanlarını ve bu araştırma konusunun üzerinde devam edecek çalışmaları arttıracaktır. Ancak bu noktada geliştirilmesi gereken en önemli

konu, sistemin, sanatçılar ve uzmanlara tanıtılması ve onların bu uygulama ile ne gibi farklı alanlarda fayda sağlanabileceğini görmesi ve bu konuda araştırmacıları ve mühendisleri teşvik etmesidir.

5 SONUÇ

Yapay zekâ sistemlerinin, modern teknoloji dünyasında son kullanıcı odaklı kullanımına bakıldığında, elektronik araçlar, analitik ve fonksiyonel bilgisayar sistemleri, mobil iletişim cihazları ve uygulamaları gibi toplumsal ve bireysel hayatta günlük yaşamın bir parçası olduğu görülmektedir. Ancak son birkaç yıl içerisinde, çeşitli yapay sinir ağı algoritmaları, bilinen elektronik ve bilgisayar uygulamaları ile birleştirilerek ses, el yazısı, sözcük tanıma gibi bazı özel uygulamalarda yapay zekâ odaklı problem çözümü için kullanılmaktadır.

Yapay sinir ağı ve yapay zekâ sistemlerinin günlük hayatın bir parçası olabilecek kadar yaygınlaşmamasının temel nedenlerinden biri, bu konularda yapılan bilimsel çalışmaların çok yeni olmasıdır. Çalışma kapsamında incelenen, yapay sinir ağlarının gelişiminin tarihçesine bakıldığında, yapay zekâ ve yapay sinir ağları üzerindeki bilimsel araştırmaların son 10 yıl içerisinde hız kazandığı görülmektedir.

Ayrıca yapay zekâ alanındaki araştırmaların mevcut bir probleme yeni bir çözüm üretebilmesi veya farklı bir uygulama alanında devrimsel bir çözüm oluşturabilmesi, nörobilim, elektronik, bilgisayar donanım, fizik, biyoloji, uygulamalı matematik, psikoloji, dilbilim gibi pek çok farklı alanlardaki bilimsel ve teknolojik gelişimlere bağımlıdır. Bilgisayar bilimleri alanında, yapay zekâ ve yapay sinir ağları ile ilgili algoritmalar, yazılımlar ve donanımlar üzerinde çok çeşitli araştırmalar yapılmasına rağmen, bu sistemlerin uygulama alanlarındaki yaygınlaşma ve yeni alanlarda gelişimi disiplinler arası araştırmalar ile ortaya çıkmaktadır.

Yapay zekâ sistemlerinin yeni uygulama alanları bulması ve yaygınlaşması, konu ile ilgili yapılan araştırmaların derinleştirilmesini, kapsamlarının genişletilmesini ve kullanılan algoritmaların, yazılım ve donanım bileşenlerinin gelişimini de sağlamaktadır. Özellikle yapay sinir ağı sistemleri alanında yapılan disiplinler arası araştırmaların niteliği ve niceliği, yapay sinir ağı sistemlerinin farklı alanlarda yaygın kullanımının sağlanması ve teknolojik gelişimi ile doğru orantılıdır. Çalışmanın bu anlamda, konu üzerinde yapılacak ulusal ve uluslararası araştırmaları tetiklemesi ve farklı bir alandan bakış açısı sunarak yapay zekâ çalışmalarında bir gelişim adımı oluşturması hedeflenmiştir.

Bu sistemler üzerinde yapılan araştırmaların bir başka gücü ise bilinen mevcut yapay zekâ sistemlerinin, alışılmış bilgisayar sistemlerinde olduğu gibi önceden

tanımlı ve özellikle kontrol amaçlı problemlerde, %100 başarılı yanıt verebilmesinin mümkün olmamasıdır. Günümüzde kullanılan bilgisayar destekli yazılım uygulamaları ve algoritmalarında ise %100 başarı hedeflenmiş, problemler ve geliştirme yöntemleri, yanlış yapmayan sistemler etrafında şekillendirilmiştir. Dolayısı ile yapay zekâ sistemleri, uygulamaya alındığında, son kullanıcıların bir bilgisayar sisteminden beklentilerinin karşılanabilmesi için, hatayı tolere edecek veya engelleyecek ek sistemler ve fonksiyonlar ile desteklenmektedir. Bu ek geliştirmeler de, yapay zekânın analitik sistemlerin çekirdeği olmasını engellerken, ek geliştirme maliyetleri oluşturarak uygulamanın zorluğunu arttırmaktadır.

Örneğin bir enerji santralini kontrol etmek için hata yapacak kadar zeki bir sistem tek başına kullanılamaz. Böyle bir sistemin kullanımı sistemin üretebileceği enerji miktarını ve verimliliğini artırıyor olsa bile karşılaşılabilecek bir hatanın yaratacağı güvenlik riskleri göze alınamayacak kadar büyüktür. Benzer bir örnek, uçuş ve hava kontrol sistemleri için de verilebilir. Bilinen hiçbir bilgisayarlı uçuş kontrol sistemi bir pilotun verebileceği esneklikte kararlar verememektedir. Buna rağmen çok sıkı güvenlik prosedürlerine uyması beklenen, insan hayatının söz konusu olduğu ticari ve askeri uçuş sistemlerinde yapay sinir ağları uygulama bulamamıştır. Bunun nedeni tıpkı bir pilotun hata yapabileceği gibi bir yapay sinir ağı sisteminin de hata yapabilecek olmasıdır. Yaygın kültürde pilotun yapabileceği hatalar ile mekanik ve fiziksel arızalardan kaynaklı hatalar istisnai kaza nedeni olarak kabul görülürken, bir yapay sinir ağı sisteminin yapabileceği hatalar olasılıksal olarak hesaplanabilir olduğundan ve istisna sayılamayacağından kabul görmemektedir.

Bu sebeple yapay sinir ağları üzerinde yapılan araştırmalarda, geliştirilen sistemin çözdüğü problemlerin zorluğu ve algoritmanın performansının yanı sıra olasılıksal hata oranı da kritik bir başarı ölçütü olarak değerlendirilmektedir. Sıfırdan büyük olasılıksal hataya sahip olan yapay zekâ sistemlerinin, bazı kritik uygulamalarda kullanılabilmesi için “false positive”(yanlış olumluluk) kavramı geliştirilmiştir. Bu kavram, bir yapay sinir ağı sisteminin hata yapması durumunda, yapılan hatanın sonuçlarının değerlendirilmesi üzerine kurulmuştur. Bu yöntemde, yapay sinir ağı sistemlerinin olası hatalı çıkışlarının ve kararlarının sonuçları değerlendirilerek, sistem, sonuçlarının getireceği zararın en az olduğu hatayı diğer hatalara göre olasılıksal olarak daha fazla yapacak ve bunun karşılığında, sonuçlara bağlı oluşacak zararların daha büyük olacağı hataları, daha az yapacak şekilde optimize edilir. Örneğin bir grup hastaya ait akciğer röntgen filmlerini giriş verisi olarak değerlendiren ve bu verilere göre hastaların kanser olup olmadığını değerlendiren bir yapay sinir ağı tabanlı karar destek sistemi, süreç içerisindeki diğer bileşenler (doktorlar, operatörler, diğer elektronik ve yazılımsal bileşenler) de göz önünde bulundurularak, kanserli hastalara kanser olmadıkları sonucunun verilmesinin mi yoksa kanser olmayan hastalara kanserli oldukları sonucunun verilmesinin mi daha fazla zarara yol açacağı göz önünde bulundurularak, optimize edilmelidir.

Ancak olasılıksal sistemlerde hata söz konusu değildir. Sonuç, sonucun oluşma olasılığı ile birlikte sunulduğu için bağımlı kontrol ve karar sistemleri bu olasılık

ışığında çalışabilirler. Çalışmanın bu noktadaki hedefi ise, yeni bir problemin sonuçlarının doğru veya yanlış olarak değil olasılıksal olarak değerlendirilebileceğini göstermektir.

Ayrıca yapay sinir ağı algoritmaları bilinen diğer analitik bilgisayar algoritmaları ile karşılaştırıldığında biyolojik sinir ağlarından esinlenerek tasarlandıkları için çok fazla işlem gücü gerektirmektedirler. İnsan beyninde yaklaşık 100 milyar sinir hücresi olduğu göz önünde bulundurulduğunda, günümüz donanım ve yazılım teknolojisi ile insan beyninin, kabul edilebilir bir hızda, herhangi bir yapay sinir ağı algoritması ile modellenmesi mümkün değildir. Bu durum çok sayıda hücresel birim ile çalışmayı ve deneyler yapmayı imkânsızlaştırmaktadır. Bu çalışma kapsamında da belirtildiği gibi, sadece yapay sinir ağlarını, kabul edilebilir performans aralıklarında çalıştıracak donanımlar ve mevcut donanımların yapay sinir ağlarını daha hızlı çalıştırabilmesi için özelleştirilmesi alanlarında yapılan çalışmalar bulunmaktadır. Ancak bu çalışmaların ilerlemesi ve gelişimi, önceki kısımlarda da belirtildiği gibi kullanım alanlarının yaygınlaşmasına ve ticarileşmeye bağlıdır.

Yapay sinir ağı sistemleri üzerinde yapılan araştırmalarda karşılaşılan zorluklara rağmen, bu sistemlerin ürettiği sonuçları herhangi bir analitik sistem ile üretmek mümkün değildir. Bu sebeple yapay sinir ağları üzerinde pek çok araştırma ve bahsi geçen sorunlara ilişkin pek çok çalışma yapılmaktadır. Yapay zekâ ve yapay sinir ağları üzerinde yapılan araştırmaların başarılarının yükselişine ve yapılan yayınların sayılarındaki artışa bakıldığında modern bilgisayar bilimlerinin karmaşık, tartışmalı ve zor konulardan biri olan yapay zekânın yakın gelecekte günlük hayatın bir parçası da olabileceği görülmektedir.

Bu tez çalışmasında yapay zekâ ile sanat ve insan algısı bir araya getirilmeye çalışılmıştır. Yapay zekâ insan davranışını keşfetmenin matematik uygulamalı bilimsel yollarından birisidir. Bir bakış açısı ile yapay sinir ağları, canlı sinir sisteminin simülasyonudur. Böyle bir sistemi geliştirmenin ve analiz etmenin bir yolu da insanla ve zekâ ile ilişkili konularda yapay zekâyı kullanmaktır. Yapay zekânın antropoloji, psikoloji ve dilbilimleri ile ilişkisi bu amaçla yapılan çalışmalardan kaynaklanmaktadır. Ancak literatüre ve son yıllarda yapılan popüler yapay zekâ araştırmalarına bakıldığında herhangi bir sanat dalında veya ilişkili olan ya da bir sanatçının eserlerini tanıma yolunda geliştirilmiş yapay zekâ uygulaması bulunmamaktadır.

Ses tanıma, yüz tanıma, el yazısı tanıma ve okuma gibi problemlere bakıldığında yapay sinir ağı sistemlerinin, insanların her gün farkında olmadan defalarca çözdükleri problemleri çözmesi hedeflenmiştir. Bu alanlarda yapılan uygulamalar, diğer matematiksel yöntemler ile ulaşılamamış başarılarla ulaşılmış ve araştırmaların derinleştirilmesine neden olmuştur. Bu çalışmalar ile yapay sinir ağlarının gelişiminde önemli rol oynayan diğer benzer çalışmalar incelendiğinde görülen ortak özellik, insanın kolaylıkla çözebildiği ancak bilinen algoritmalar ile çözüme ulaştırılamayan problemlere çözüm oluşturabilmeleridir. Sadece insanın başarılı

olarak çözebildiği bu problemlerin, bilgisayar sistemleri ile çözülmesi bilim dünyasında büyük bir başarı olarak görülmektedir. Çalışmanın hipotezi ve prototip uygulamanın tasarımının temel hedefi böyle bir probleme çözüm oluşturmaktır. Çünkü her ne kadar insan beyni bir bilgisayar sistemi ile karşılaştırılmayacak kadar karmaşık ve yetenekli olsa da, bilgisayar sistemlerinin de büyük avantajları bulunmaktadır. Bir bilgisayar sisteminin işlem gücü ve işlem yeteneği insan beyninin tasarlayabildiği veya programlayabildiği kadardır. Ancak günümüz teknolojisinde bilgisayar sistemlerinin fiziksel ve elektronik yapısı, bu sistemlerin neredeyse sonsuz büyüklükte veriyi hatasız şekilde saklayabilmesine ve bu verilere milisaniyeler içerisinde erişebilmesine izin vermektedir. Bilgisayar sistemlerinin, insan zekâsını satranç gibi belirli kurallara sahip zekâ oyunlarında yenebiliyor olması, veriyi hatasız saklayabilme ve anında erişim matematiksel ve mantıksal olarak milyonlarca olasılığı milisaniyeler içinde değerlendirebilmesinden kaynaklıdır. Ancak gerçek hayat problemlerinin büyük çoğunluğunda kurallar belirsiz veya tanımsızdır. Dolayısı ile bilgisayar sistemlerinin bu yeteneği ile insan zekâsının esnekliği ve yaratıcılığı sentezlenebilirse kendi kendini programlayabilen, geliştirebilen veya üretebilen makineler yapmak teoride mümkündür. Bu teori yapay sinir ağları üzerinde yapılan araştırmaların doğal itici gücü olmuştur.

Bu tez kapsamında test edilen problemde insan beyninin farkında olmadan çözdüğü ancak bilgisayar sistemlerinin matematiksel olarak bilinen yöntemlerle modelleyip çözemediği bir problemdir. Çalışma kapsamında sanat ve resim konuları da araştırma konusunun nesnesi olarak işlenerek, çalışmanın farklı disiplinlerin dikkatini çekmesi ve yeni araştırma konuları ile yapay sinir ağları mimarisinde oluşturulacak yeni çözümlere öncü olması hedeflenmiştir.

Çalışmanın başlangıcından, prototip uygulamanın test edilmesine kadar olan süreçte, ileri sürülen hipotezi destekleyecek araştırma sorularına, özellikle geliştirilen prototip uygulama üzerinde gerçekleştirilen deneyler ve literatür taraması ile yanıt bulunmuştur. Öncelikle yapay zekâ kavramı, yapay sinir ağlarının gelişimi, bu alanlarda yaşanan yanılgılar ve başarılar belirlenmiştir. Yapay sinir ağı sistemlerinin gelişimde olumlu veya olumsuz etkileri ile dikkat çeken ve dönüm noktası sayılan çalışmalar ile bu çalışmaların akademik çevrelerde ve teknolojiye yarattığı sonuçlar geçmiş gelişim süreci içerisinde incelenmiştir. Daha sonra günümüz bilim dünyasında yaygın olarak kabul görmüş, en yeni yapay zekâ ve yapay sinir ağı teknolojileri ve bunların uygulamaları ile başarıları araştırılmıştır. Hangi algoritmaların neden ortaya çıktığı, bu algoritmaların üzerindeki çalışmaları doğuran ihtiyaçlar ve düşünsel süreçler, farklı problem türlerinin hangilerini çözmeye daha başarılı oldukları kaynak taraması ile araştırılmıştır. Bu modern tekniklerden, Kısıtlı Boltzmann Makineleri ile yapılan benzer uygulamalara bakıldığında, sistemlerin birleşik veya tümleşik olarak çalıştırılarak ve en iyileştirme süreçleri ile verileri sınıflandırma, görüntüleri etiketleme ve insan yüzlerini tanıma gibi problemleri geçmişteki yöntemlere göre daha yüksek başarı oranları ile tespit edildiği görülmüş,

bu algoritmanın sanatçı tanıma problemi üzerinde test edilmeye uygun olduğu saptanmıştır.

Yapılan literatür taramasında görüntüleri farklı sanatçılar ile bağdaştırabilen herhangi bir sisteme veya böyle bir sistemi öngören bir yayına rastlanmamıştır. Dolayısı ile bu noktadan sonra yapay zekânın, sanatçıları yüksek gürültü içeren verilerden bile tanıyabileceği fikrini desteklemek için, en yeni ve başarısı ispatlanmış yapay sinir ağı algoritmalarından biri olan Kısıtlı Boltzmann makineleri ile geliştirilebilecek bir sistem öngörülmüş ve bir prototip uygulama geliştirilmiştir.

Uygulama Java programlama dili ile geliştirilmiştir. Java programlama dili, açık kaynak kodlu yazılım geliştirmeyi teşvik etmesi, nesneye yönelik yapısı ile problemleri modellemeyi kolaylaştırması, arayüz programlama için kütüphaneler sunması, ücretsiz olması, akademik çevrelerde yaygın kullanımı, farklı platformlarda ve işletim sistemlerinde çalışabilmesi gibi nedenlerden dolayı tercih edilmiştir. Böylece uygulamanın kullanılabilirliği, incelenebilirliği ve geliştirilebilirliği daha geniş bir ortam hedeflenmiştir.

Geliştirilen prototip uygulama yazılımı, üzerinde gerçekleştirilen deney sonuçları ile çalışmada ileri sürülen hipotezi desteklemiş, uygulamanın yazılımsal ve algoritmik iyileştirmeler ile başarısının arttırılabileceğini göstermiştir.

Özellikle uluslararası ve ulusal literatürde konu ile ilgili veya benzer konularda yapılan araştırmaların sayıca az oluşu, bu çalışmanın önemini ve öncülüğünü daha da öne çıkarmaktadır. Sanat dışında pek çok farklı alanda üzerinde çalışmalar yapılan yapay zekâ uygulamalarının, sanat alanında kullanılması ve gerçek bir yazılım ile desteklenmesi çalışmayı yenilikçi ve işlevsel bir araştırma haline getirmiştir. Sanatın insan zekâsının en karmaşık üretimlerinden biri olduğu düşünülürse, yapay zekâ ile sanatı tanımlamanın bir sonraki adımının, sanat yapan makineler olduğu öngörülebilir. Böyle bir uygulama yakın gelecekte mümkün görünmemekle birlikte, zekâ, sanat ve yaratıcılığın tanımlarını tamamen değiştirecek yeni araştırmaları ve tartışmaları ortaya çıkaracağı kesindir.

Gelecekte de bu konu üzerinde çalışmalara devam edilecektir. Sonraki adımlar bölümünde de bahsedildiği gibi uygulama yazılımı bir prototiptir ve üzerindeki iyileştirme çalışmaları hipotezi destekleyecek kadar yapılmıştır. Ancak bu uygulamanın başarı oranının %95 gibi değerlerin üzerine çıkarılması, çalışmanın bilinirliğini arttırarak, yapay sinir ağlarının yeteneklerine bakış açısına sanat alanında boyut kazandıracak ve yeni araştırmaların doğmasını sağlayacaktır.

Sonuç olarak çalışmanın sanatta yeni uygulama alanları bularak, yapay zekâ ile ilişkili gelişmelerle paralel biçimde daha da başarılı olması, sanat ve yapay zekâ kavramları arasında bilimsel araştırmaları ve gelişimleri tetikleyecek bir köprü oluşturması, yenilikçi ve bilimsel bir ulusal, uluslararası kaynak ve konu ile ilgili yeni bilimsel araştırmalara öncü olması beklenmektedir.

KAYNAKLAR

Berardi, M., Lapi, M., & Malerba, D. (2004). *An Integrated Approach for Automatic Semantic Structure Extraction in Document Images*. Bari: Dipartimento di Informatica.

Biederman, I. (1987). Recognition By Components: A Theory of Human Image Understanding. *Psychological Review Vol. 94, No. 2* , 115-147.

Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford: Oxford University Press.

Cerny, V. (1985). A thermodynamical approach to the travelling salesman problem: an efficient simulation algorithm. *Journal of Optimization Theory and Applications* , 45 , 41-51.

Chen, T., Yin, W., Zhou, X. S., Comaniciu, D., & Huang, T. S. (2005). *Illumination Normalization for Face Recognition and Uneven Background Correction Using Total Variation Based Image Models*. University of Illinois at Urbana Champaign, Columbia University, Siemens Corporate Research.

Cruse, H. *Neural Networks as Cybernetic Systems 2nd and revised edition*.

CRUSE, H., STEINKÜHLER, U., & BURKAMP, C. (1998). MMC - a recurrent neural network which can be used as manipulable body model.

Doyle, J. (1983). What is Rational Psychology? Toward a Modern Mental Philosophy. *AI Magazine 4(3)* , 50-53.

Evening, M. *Adobe Photoshop CS2 for Photographers*. ISBN: 0 240 51984 1.

Fausett, L. (1994). *Fundamentals of Neural Networks*. PrenticeHall.

H. J. van den Herik, E. O. (1999). *The Hand of the Master. An analysis of the Visual Signatures of Painters*. R. Timman Foundation.

Haykin, S. (1995). *Neural Networks*. New York: Macmillan College Publishing Company.

Hebb, D. (1949). *The Organization of Behavior*.

- Heingartner, & Douglas. (2004, June 13). A Computer That Has An Eye for Van Gogh. *The New York Times* .
- Hinton, G. E. (2002). Training products of experts by minimizing contrastive divergence. *Neural Computing* vol. 14, no. 8 , 1771–1800.
- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313 , 504-507.
- Hinton, G. E., & Sejnowski, T. J. (1983). Optimal Perceptual Inference. *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition* (s. 448-453). Washington DC: IEEE.
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural Comp.* 18(7) , 1527–1554.
- Kargel, D., & Brandt, W. (1993). *Image Understanding Using Artificial Intelligence Technology*. AAAI Technical Report WS-93-04.
- Kirkpatrick, S., Gelatt, C. D., & Vecchi, M. P. (1983). Optimization by Simulated Annealing.
- Mandic, D., & Chambers, J. (2001). *Recurrent Neural Networks for Prediction: Learning Algorithms, Architectures and Stability*. New York: John Wiley & Sons.
- Mateas, M. (2002). *Interactive Drama, Art and Artificial Intelligence*. Pittsburgh: Computer Science Department, Carnegie Mellon University.
- McAfee, L. (2009). Design and Analysis of BLAS, GPU, and Sparse Multithreaded Acceleration Methods for Restricted Boltzmann Machine Training.
- Meger, D., Forssen, P.-E., Lai, K., Hemler, S., McCann, S., Southey, T., et al. *Curious George, An Attentive Semantic Robot*. Vancouver: Department of Computer Science, University of British Columbia.
- Metropolis, N., Rosenbluth, A., Rosenbluth, M., Teller, A., & Teller, E. (1953). Equations of State Calculations by Fast Computing Machines. *Journal of Chemical Physics*, 21(6) , 1087-1092.
- Minsky, M., & Papert, S. (1969). *Perceptrons*. Cambridge: MIT Press.
- Pearl, J. (1988). *Probabilistic reasoning in intelligent systems : networks of plausible inference*. San Mateo: Morgan Kaufmann Publishers.
- Pfeifer, R., Blumberg, B., Meyer, J.-A., & Wilson, S. *From Animal to Animats 5*. Cambridge: MIT Press.
- Simon, H. (1994). Omni Magazine, Interview with Herbert Simon. (D. Stewart, Röportajı Yapan)

- Smolensky, P. (1986). Parallel distributed processing: explorations in the microstructure of cognition, vol. 1. P. Smolensky içinde, *Parallel distributed processing: explorations in the microstructure of cognition, vol. 1* (s. 194–281). Cambridge: MIT Press.
- Teh, Y. W., & Hinton, G. E. (2000). Rate-coded Restricted Boltzmann Machines for Face Recognition.
- Wang, J. Z., & Li, J. (2008). Real-Time Computerized Annotation of Pictures. *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE* .
- Wang, J. Z., Li, J., & Wiederhold, G. (2001). SIMPLIcity: Semantics-sensitive integrated matching for picture libraries. *IEEE Transaction on Pattern Analysis and Machine Intelligence, vol. 23, no. 9* , 947-963.
- Zhao, W., Chellappa, R., Rosenfeld, A., & Phillips, P. (2000). *Face Recognition: A literature Survey*. University Of Maryland.








EKLER





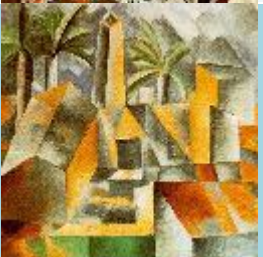
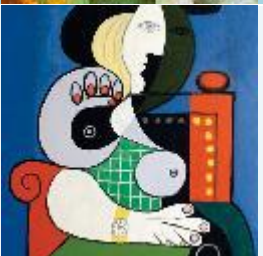

Ek 1 : Prototip Uygulama Eğitim Verisi Görüntüleri








No	Dosya Adı	Görüntü Boyutları	Görüntü
1	1887-88 Skull.jpg	500x693	
2	cgfa_dali1.jpg	800x568	
3	dali-anthony.jpg	750x550	
4	dali-slavemarket.jpg	1072x745	
5	dali-swans-reflecting-elephants.jpg	1024x660	








6	dali.dreambeepomegranate.jpg	1000x1273	
7	dali.jpg	691x487	
8	dali1.jpg	726x1139	
9	dali3.jpg	756x1026	
10	dali3a.JPG	529x816	
11	dali5.jpg	560x683	
12	dali_cannibalism-autumn.jpg	910x937	


13	Dali_Madonna_of_Port_Lligat_1950a.jpg	640x881	
14	dali_pma_05_09.jpg	1800x1401	
15	Gala close up Escerpt 1 Salvador Dali Original Studio Litho.JPG	800x753	
16	gogh.olive-trees.jpg	1024x820	
17	guernica_pablo_picasso.jpg	1112x804	
18	lastsuppersalvadordali.jpg	700x450	
19	Metamorphosis_of_Narcissus,_1936-1937,_Salvador_Dali.jpg	1152x768	

20	Pablo Picasso.jpeg	520x661	
21	pabl_picasso_cavalier_with_pipe.jpg	507x708	
22	Picasso-3women.jpg	869x977	
23	picasso-avignon.jpg	982x1026	
24	picasso-the_dream-surrelism.jpg	838x1154	
25	picasso139.JPG	507x657	
26	picasso146.JPG	570x711	

27	picasso3.jpg	642x930	
28	picasso_3musicians1921.jpg	639x600	
29	picasso_arlequin_sothebys.jpg	1618x1967	
30	Picasso_Demoiselles.jpg	982x1026	
31	Picasso_Factory_at_Horta_de_Ebro_1909.jpg	962x804	
32	picasso_woman_b.jpg	500x680	
33	Sleep_- _Le_Sommeil_Salvador_Dali.jpg	1024x768	






34	The-Kiss-by-Picasso-fine-art-691990_1024_768.jpg	1024x746	
35	Van Gogh's Room at Arles.JPG	640x487	
36	van gogh.jpg	479x653	
37	van-gogh-potato-eaters.jpg	887x626	
38	van-gogh-shoes2.jpg	1500x1208	
39	vangogh-starry_night_ballance1.jpg	1755x1410	
40	vangoghsower1.jpg	750x592	







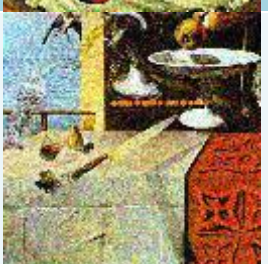
41	VanGogh_VanGogh.jpg	1020x1360	
42	van_gogh_128.jpg	2024x2531	
43	van_gogh_bandaged.jpg	543x613	
44	Van_Gogh_Night_Cafe_1888.jpg	748x594	
45	Vincent-van-Gogh-707405.jpg	846x1020	
46	Vincent_van_Gogh_GOV015.jpg	589x700	
47	Vincent_Willem_van_Gogh_015.jpg	2024x2539	




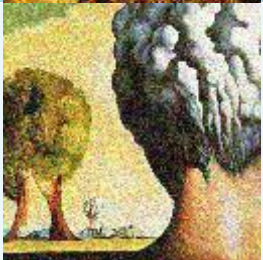


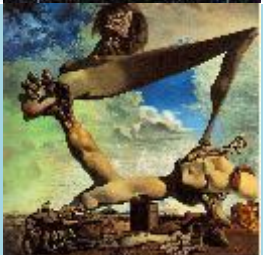
48	ZZ Dali's Christ of St John of the Cross 1951.jpg	656x708	
----	---	---------	---








Ek 2 : Prototip Uygulama Deney Verisi ve Deney Sonuçları








Salvador Dali








Veri No	Analiz Sonucu	Görüntü Boyutu	Görüntü
1	% 59 Pablo Picasso % 63 Salvador Dali % 79 Van Gogh	718x738	
2	% 93 Pablo Picasso % 34 Salvador Dali % 73 Van Gogh	846x610	
3	% 51 Pablo Picasso % 91 Salvador Dali % 49 Van Gogh	819x614	
4	% 79 Pablo Picasso % 89 Salvador Dali % 36 Van Gogh	520x455	
5	% 56 Pablo Picasso % 96 Salvador Dali % 46 Van Gogh	1200x1011	

6	% 48 Pablo Picasso % 98 Salvador Dali % 51 Van Gogh	1440x1121	
7	% 54 Pablo Picasso % 90 Salvador Dali % 53 Van Gogh	581x911	
8	% 52 Pablo Picasso % 71 Salvador Dali % 77 Van Gogh	819x614	
9	% 74 Pablo Picasso % 52 Salvador Dali % 78 Van Gogh	1982x2736	
10	% 56 Pablo Picasso % 59 Salvador Dali % 84 Van Gogh	950x1212	
11	% 48 Pablo Picasso % 67 Salvador Dali % 84 Van Gogh	853x754	
12	% 61 Pablo Picasso % 44 Salvador Dali % 98 Van Gogh	819x614	



13	% 39 Pablo Picasso % 72 Salvador Dali % 87 Van Gogh	900x588	
14	% 63 Pablo Picasso % 87 Salvador Dali % 32 Van Gogh	1226x800	
15	% 31 Pablo Picasso % 88 Salvador Dali % 55 Van Gogh	728x750	
16	% 64 Pablo Picasso % 72 Salvador Dali % 63 Van Gogh	640x493	
17	% 52 Pablo Picasso % 99 Salvador Dali % 50 Van Gogh	819x614	
18	% 42 Pablo Picasso % 94 Salvador Dali % 48 Van Gogh	960x606	
19	% 64 Pablo Picasso % 86 Salvador Dali % 51 Van Gogh	897x922	

20	% 63 Pablo Picasso % 75 Salvador Dali % 63 Van Gogh	1057x762	
21	% 49 Pablo Picasso % 99 Salvador Dali % 50 Van Gogh	800x568	
22	% 35 Pablo Picasso % 87 Salvador Dali % 52 Van Gogh	1024x768	
23	% 49 Pablo Picasso % 99 Salvador Dali % 50 Van Gogh	750x550	
24	% 54 Pablo Picasso % 81 Salvador Dali % 70 Van Gogh	2478x3420	
25	% 55 Pablo Picasso % 59 Salvador Dali % 88 Van Gogh	1066x943	
26	% 49 Pablo Picasso % 99 Salvador Dali % 51 Van Gogh	1072x745	




27	% 49 Pablo Picasso % 99 Salvador Dali % 50 Van Gogh	1024x660	
28	% 49 Pablo Picasso % 99 Salvador Dali % 50 Van Gogh	1000x1273	
29	% 49 Pablo Picasso % 99 Salvador Dali % 50 Van Gogh	691x487	
30	% 50 Pablo Picasso % 98 Salvador Dali % 50 Van Gogh	726x1139	
31	% 50 Pablo Picasso % 99 Salvador Dali % 50 Van Gogh	756x1026	
32	% 53 Pablo Picasso % 67 Salvador Dali % 75 Van Gogh	529x816	
33	% 50 Pablo Picasso % 99 Salvador Dali % 50 Van Gogh	560x683	


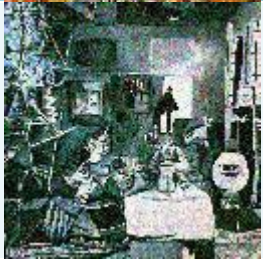





34	% 60 Pablo Picasso % 53 Salvador Dali % 99 Van Gogh	1024x768	
35	% 50 Pablo Picasso % 99 Salvador Dali % 49 Van Gogh	910x937	
36	% 65 Pablo Picasso % 73 Salvador Dali % 63 Van Gogh	650x569	
37	% 50 Pablo Picasso % 99 Salvador Dali % 49 Van Gogh	640x881	
38	% 51 Pablo Picasso % 88 Salvador Dali % 44 Van Gogh	1500x1264	
39	% 50 Pablo Picasso % 99 Salvador Dali % 48 Van Gogh	1800x1401	
40	% 50 Pablo Picasso % 98 Salvador Dali % 50 Van Gogh	726x1139	








41	% 50 Pablo Picasso % 99 Salvador Dali % 49 Van Gogh	1125x735	
42	% 94 Pablo Picasso % 64 Salvador Dali % 43 Van Gogh	800x753	
43	% 44 Pablo Picasso % 95 Salvador Dali % 48 Van Gogh	1532x1000	
44	% 50 Pablo Picasso % 99 Salvador Dali % 49 Van Gogh	700x450	
45	% 50 Pablo Picasso % 99 Salvador Dali % 49 Van Gogh	1152x768	
46	% 50 Pablo Picasso % 99 Salvador Dali % 49 Van Gogh	910x937	
47	% 48 Pablo Picasso % 89 Salvador Dali % 52 Van Gogh	800x616	








48	% 50 Pablo Picasso % 99 Salvador Dali % 49 Van Gogh	1024x768	
49	% 47 Pablo Picasso % 96 Salvador Dali % 48 Van Gogh	1024x768	
50	% 49 Pablo Picasso % 99 Salvador Dali % 49 Van Gogh	656x708	








Pablo Picasso



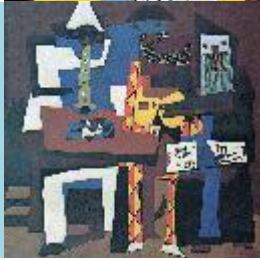




Veri No	Analiz Sonucu	Görüntü Boyutu	Görüntü
1	% 72 Pablo Picasso % 55 Salvador Dali % 80 Van Gogh	1221x1230	
2	% 72 Pablo Picasso % 67 Salvador Dali % 59 Van Gogh	638x803	
3	% 70 Pablo Picasso % 25 Salvador Dali % 92 Van Gogh	533x517	

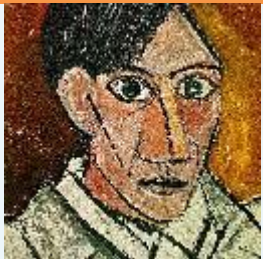






4	% 72 Pablo Picasso % 62 Salvador Dali % 67 Van Gogh	786x821	
5	% 66 Pablo Picasso % 91 Salvador Dali % 47 Van Gogh	854x631	
6	% 52 Pablo Picasso % 54 Salvador Dali % 93 Van Gogh	735x1154	
7	% 88 Pablo Picasso % 27 Salvador Dali % 66 Van Gogh	1097x1394	
8	% 64 Pablo Picasso % 70 Salvador Dali % 68 Van Gogh	786x821	
9	% 82 Pablo Picasso % 51 Salvador Dali % 35 Van Gogh	791x675	
10	% 51 Pablo Picasso % 49 Salvador Dali % 98 Van Gogh	646x994	






11	% 98 Pablo Picasso % 51 Salvador Dali % 44 Van Gogh	606x910	
12	% 61 Pablo Picasso % 67 Salvador Dali % 70 Van Gogh	663x979	
13	% 94 Pablo Picasso % 43 Salvador Dali % 60 Van Gogh	658x802	
14	% 88 Pablo Picasso % 82 Salvador Dali % 32 Van Gogh	643x818	
15	% 66 Pablo Picasso % 76 Salvador Dali % 59 Van Gogh	614x819	
16	% 67 Pablo Picasso % 59 Salvador Dali % 78 Van Gogh	695x782	
17	% 91 Pablo Picasso % 53 Salvador Dali % 43 Van Gogh	477x433	

18	% 84 Pablo Picasso % 61 Salvador Dali % 56 Van Gogh	670x930	
19	% 52 Pablo Picasso % 80 Salvador Dali % 67 Van Gogh	878x851	
20	% 93 Pablo Picasso % 62 Salvador Dali % 48 Van Gogh	819x614	
21	% 88 Pablo Picasso % 59 Salvador Dali % 56 Van Gogh	1526x1538	
22	% 64 Pablo Picasso % 86 Salvador Dali % 52 Van Gogh	797x1004	
23	% 74 Pablo Picasso % 29 Salvador Dali % 94 Van Gogh	666x646	
24	% 99 Pablo Picasso % 50 Salvador Dali % 50 Van Gogh	982x1026	


25	% 64 Pablo Picasso % 69 Salvador Dali % 71 Van Gogh	1067x789	
26	% 56 Pablo Picasso % 54 Salvador Dali % 90 Van Gogh	919x1442	
27	% 99 Pablo Picasso % 51 Salvador Dali % 49 Van Gogh	520x661	
28	% 79 Pablo Picasso % 77 Salvador Dali % 46 Van Gogh	1371x1743	
29	% 99 Pablo Picasso % 50 Salvador Dali % 49 Van Gogh	507x708	
30	% 99 Pablo Picasso % 49 Salvador Dali % 50 Van Gogh	869x977	
31	% 99 Pablo Picasso % 50 Salvador Dali % 49 Van Gogh	982x1026	




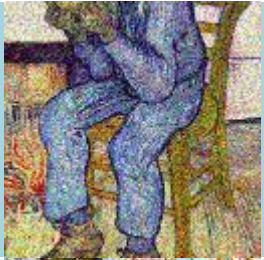



32	% 65 Pablo Picasso % 64 Salvador Dali % 74 Van Gogh	596x541	
33	% 99 Pablo Picasso % 49 Salvador Dali % 50 Van Gogh	838x1162	
34	% 58 Pablo Picasso % 70 Salvador Dali % 75 Van Gogh	1097x1064	
35	% 99 Pablo Picasso % 50 Salvador Dali % 50 Van Gogh	982x1026	
36	% 45 Pablo Picasso % 61 Salvador Dali % 94 Van Gogh	507x657	
37	% 53 Pablo Picasso % 66 Salvador Dali % 80 Van Gogh	570x711	
38	% 68 Pablo Picasso % 45 Salvador Dali % 85 Van Gogh	823x1003	




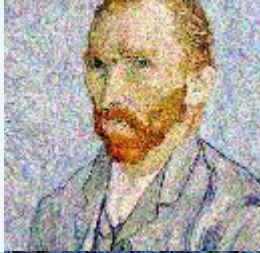



39	% 99 Pablo Picasso % 51 Salvador Dali % 49 Van Gogh	804x1022	
40	% 73 Pablo Picasso % 74 Salvador Dali % 52 Van Gogh	768x1024	
41	% 99 Pablo Picasso % 49 Salvador Dali % 50 Van Gogh	639x600	
42	% 99 Pablo Picasso % 50 Salvador Dali % 50 Van Gogh	1618x1967	
43	% 99 Pablo Picasso % 50 Salvador Dali % 50 Van Gogh	982x1026	
44	% 93 Pablo Picasso % 47 Salvador Dali % 50 Van Gogh	989x844	
45	% 59 Pablo Picasso % 46 Salvador Dali % 95 Van Gogh	808x1243	








46	% 90 Pablo Picasso % 70 Salvador Dali % 37 Van Gogh	758x1138	
47	% 79 Pablo Picasso % 68 Salvador Dali % 57 Van Gogh	829x1224	
48	% 67 Pablo Picasso % 85 Salvador Dali % 51 Van Gogh	858x1171	
49	% 99 Pablo Picasso % 50 Salvador Dali % 51 Van Gogh	500x680	
50	% 99 Pablo Picasso % 50 Salvador Dali % 50 Van Gogh	1024x768	








Vincent Van Gogh








Veri No	Analiz Sonucu	Görüntü Boyutu	Görüntü
1	% 68 Pablo Picasso % 78 Salvador Dali % 49 Van Gogh	1013x822	




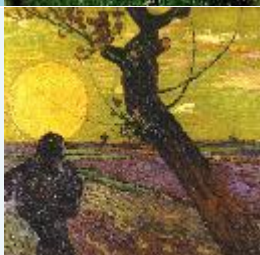



2	% 73 Pablo Picasso % 78 Salvador Dali % 53 Van Gogh	810x658	
3	% 79 Pablo Picasso % 24 Salvador Dali % 92 Van Gogh	821x662	
4	% 90 Pablo Picasso % 13 Salvador Dali % 98 Van Gogh	1026x827	
5	% 68 Pablo Picasso % 41 Salvador Dali % 92 Van Gogh	1005x1289	
6	% 77 Pablo Picasso % 86 Salvador Dali % 43 Van Gogh	849x646	
7	% 52 Pablo Picasso % 93 Salvador Dali % 58 Van Gogh	829x672	
8	% 83 Pablo Picasso % 35 Salvador Dali % 52 Van Gogh	652x839	







9	% 50 Pablo Picasso % 56 Salvador Dali % 93 Van Gogh	819x642	
10	% 51 Pablo Picasso % 51 Salvador Dali % 98 Van Gogh	383x522	
11	% 65 Pablo Picasso % 58 Salvador Dali % 81 Van Gogh	434x490	
12	% 68 Pablo Picasso % 63 Salvador Dali % 70 Van Gogh	816x1088	
13	% 64 Pablo Picasso % 94 Salvador Dali % 37 Van Gogh	1082x506	
14	% 47 Pablo Picasso % 64 Salvador Dali % 88 Van Gogh	661x810	
15	% 45 Pablo Picasso % 87 Salvador Dali % 70 Van Gogh	1200x966	

16	% 47 Pablo Picasso % 92 Salvador Dali % 65 Van Gogh	1503x1200	
17	% 78 Pablo Picasso % 11 Salvador Dali % 87 Van Gogh	1619x2025	
18	% 50 Pablo Picasso % 71 Salvador Dali % 76 Van Gogh	471x560	
19	% 38 Pablo Picasso % 87 Salvador Dali % 50 Van Gogh	654x492	
20	% 44 Pablo Picasso % 55 Salvador Dali % 98 Van Gogh	1619x2031	
21	% 49 Pablo Picasso % 49 Salvador Dali % 99 Van Gogh	500x693	
22	% 77 Pablo Picasso % 10 Salvador Dali % 85 Van Gogh	1619x2025	

23	% 69 Pablo Picasso % 66 Salvador Dali % 64 Van Gogh	677x830	
24	% 61 Pablo Picasso % 52 Salvador Dali % 91 Van Gogh	460x600	
25	% 76 Pablo Picasso % 50 Salvador Dali % 73 Van Gogh	1256x1611	
26	% 88 Pablo Picasso % 81 Salvador Dali % 33 Van Gogh	1061x808	
27	% 43 Pablo Picasso % 84 Salvador Dali % 77 Van Gogh	1036x840	
28	% 82 Pablo Picasso % 34 Salvador Dali % 82 Van Gogh	1000x820	
29	% 95 Pablo Picasso % 55 Salvador Dali % 53 Van Gogh	815x1049	

30	% 49 Pablo Picasso % 83 Salvador Dali % 67 Van Gogh	1523x1877	
31	% 40 Pablo Picasso % 93 Salvador Dali % 77 Van Gogh	1024x803	
32	% 87 Pablo Picasso % 77 Salvador Dali % 36 Van Gogh	640x487	
33	% 49 Pablo Picasso % 49 Salvador Dali % 99 Van Gogh	479x653	
34	% 49 Pablo Picasso % 50 Salvador Dali % 99 Van Gogh	887x626	
35	% 49 Pablo Picasso % 51 Salvador Dali % 99 Van Gogh	1500x1208	
36	% 49 Pablo Picasso % 51 Salvador Dali % 98 Van Gogh	2024x2531	

37	% 45 Pablo Picasso % 70 Salvador Dali % 86 Van Gogh	1879x1500	
38	% 50 Pablo Picasso % 51 Salvador Dali % 99 Van Gogh	1020x1360	
39	% 48 Pablo Picasso % 70 Salvador Dali % 77 Van Gogh	826x1012	
40	% 50 Pablo Picasso % 51 Salvador Dali % 99 Van Gogh	750x592	
41	% 54 Pablo Picasso % 95 Salvador Dali % 56 Van Gogh	1353x633	
42	% 50 Pablo Picasso % 51 Salvador Dali % 99 Van Gogh	1020x1360	
43	% 49 Pablo Picasso % 51 Salvador Dali % 98 Van Gogh	2024x2531	

44	% 49 Pablo Picasso % 51 Salvador Dali % 99 Van Gogh	543x613	
45	% 49 Pablo Picasso % 50 Salvador Dali % 99 Van Gogh	748x594	
46	% 70 Pablo Picasso % 62 Salvador Dali % 68 Van Gogh	846x1038	
47	% 35 Pablo Picasso % 81 Salvador Dali % 81 Van Gogh	817x615	
48	% 49 Pablo Picasso % 51 Salvador Dali % 99 Van Gogh	589x700	
49	% 50 Pablo Picasso % 50 Salvador Dali % 99 Van Gogh	2024x2539	
50	% 49 Pablo Picasso % 51 Salvador Dali % 99 Van Gogh	2024x2531	