

YAPAY SİNİR AĞLARI

Prof.Dr. Ercan ÖZTEMEL

PAPATYA YAYINCILIK

İstanbul, Ankara, İzmir, Adana

Papatya Yayıncılık Eğitim

© PAPATYA YAYINCILIK EĞİTİM

BİLGİSAYAR SİS. SAN. VE TİC. A.Ş.

Ankara Cad. Prof. F. Kerim Gökay Vakfı İşhanı Girişi

No:11/3, 34110, Cağaloğlu / İstanbul

Tel : 0212-527 52 96, Faks: 0212-527 52 97

GSM : 0532-311 31 10

e-posta : admin@papatya.gen.tr

Web : www.papatya.gen.tr
www.papatya.info.tr

Türkiye'nin İnternet Kitapçısı - www.tdk.com.tr

Yapay Sinir Ağları – Prof. Dr. Ercan ÖZTEMEL

3. Basım Nisan 2012

Bu kitabın ilk baskısı 2003, ikinci baskısı 2006 yılında yapılmıştır.

Yayına Hazırlayan : Dr. Rifat ÇÖLKESEN
Türk Dili Uzmanı : Necdet AVCI ve Ziya ÇÖLKESEN
Üretim : Olcay KAYA
Satış : Mustafa DEMİR
Pazarlama : Batuhan AVCI
Sayfa Düzenleme : Papatya & Kelebek Tasarım
Kapak Tasarım : Papatya & Kelebek Tasarım
Basım ve Ciltleme : Altan Basım San. Ltd. Şti. (Sertifika No:11968) / İstanbul

© Bu kitabın her türlü yayın hakkı Papatya Yayıncılık Eğitim AŞ'ye aittir. Yayınevinden yazılı izin alınmaksızın alıntı yapılamaz, kısmen veya tamamen hiçbir şekil ve teknikle ÇOĞALTILAMAZ, BASILAMAZ, YAYIMLANAMAZ. Kitabın, tamamı veya bir kısmının fotokopi makinesi, ofset gibi teknikle çoğaltılması, hem çoğaltan hem de bulunduranlar için yasadışı bir davranıştır.

Lütfen kitabımızın fotokopi yöntemiyle çoğaltılmasına engel olunuz. Fotokopi hızsızlıktır.

Öztemel, Ercan.

Yapay Sinir Ağları / Ercan Öztemel. – İstanbul: Papatya Yayıncılık Eğitim, 2012

xxii, 232s. ; 24 cm.

Kaynakça ve dizin var.

Sertifika No: 11218

ISBN: 978-975-6797-39-6.

1. Yapay Zeka. 2. Öğretmenli Öğrenme. 3. Hopfield Ağı. 4. Kohonen Katmanı. 5. LVQ Ağı
I. Title

bilgi@papatya.gen.tr

Yapay Sinir Ağları

hayat arkadaşına...

www.papatya.gen.tr

TEŞEKKÜR

Bu kitabın yazılmasında bana her türlü anlayışı gösteren başta eşim ve çocuklarım olmak üzere yanımda çalışan ve kendilerini zaman zaman ihmal ettiğim proje ekibime gösterdikleri her türlü anlayıştan dolayı teşekkür ederim.

Ayrıca kitabın basılması için beni cesaretlendiren Dr .Yalçın ÖZKAN'a ve kitabın titizlikle hazırlanmasına, dizgisine, tasarımına ve basımından dağıtımına kadar bütün aşamalarında emeği geçen Papatya Yayıncılık çalışanlarına, özellikle yayın ve akademik danışmanı Dr .Rifat ÇÖLKESEN'e teşekkür ederim.

Prof. Dr. Ercan Öztemel
Mart 2003 - İstanbul

İÇİNDEKİLER

ÖNSÖZ	11
<u>Bölüm 1. YAPAY ZEKA VE MAKİNE ÖĞRENMESİNE GENEL BAKIŞ</u>	13
1.1. Yapay Zeka Teknolojisine Genel Bir Bakış	13
1.2. Yapay Zeka Teknolojileri	15
1.3. Makine Öğrenmesi ve Öğrenme Türleri	21
1.4. Öğrenme Paradigmaları	23
1.5. Örneklerden Öğrenme	23
1.6. Öğrenme Stratejileri	25
1.6.1. Öğretmenli (<i>Supervised</i>) Öğrenme	25
1.6.2. Destekleyici (<i>Reinforcement</i>) Öğrenme	25
1.6.3. Öğretmensiz (<i>Unsupervised</i>) Öğrenme	25
1.6.4. Karma Stratejiler	25
1.7. Öğrenme Kuralları	26
1.7.1. Çevrimiçi (<i>On-line</i>) Öğrenme Kuralları	26
1.7.2. Çevrimdışı (<i>Off-line</i>) Öğrenme Kuralları	26
1.7.3. Öğrenme Kurallarından Bazıları	26
1.8. Özet	27
1.9. Kaynakça	28
<u>Bölüm 2. YAPAY SİNİR AĞLARINA GİRİŞ</u>	29
2.1. Yapay Sinir Ağlarının Genel Tanımı	29
2.2. Yapay Sinir Ağı Tanımı ve En Temel Görevi	29
2.3. Yapay Sinir Ağlarının Genel Özellikleri	31
2.4. Yapay Sinir Ağlarının Önemli Dezavantajları	34
2.5. Yapay Sinir Ağları İle Neler Yapılabilir?	35
2.6. Yapay Sinir Ağlarının Kısa Bir Tarihçesi	37
2.6.1. 1970 Öncesi Çalışmalar	37
2.6.2. 1970 Sonrası Çalışmalar	39
2.7. Özet	41
2.8. Kaynakça	42
<u>Bölüm 3. YAPAY SİNİR AĞLARININ YAPISI VE TEMEL ELEMANLARI</u>	45
3.1. Biyolojik Sinir Hücreleri	45
3.2. Yapay Sinir Hücresi (Proses Elemanı)	48
3.3. Yapay Sinir Hücresinin Çalışma İlkesi	52

3.4. Yapay Sinir Ağının Yapısı	52
3.5. Yapay Sinir Ağlarının Çalışması (Kara Kutu Yakıştırması)	54
3.6. Yapay Sinir Ağlarında Öğrenme, Adaptif Öğrenme ve Test Etme	55
3.7. Yapay Sinir Ağlarında Bilgi ve Zeka	56
3.8. Yapay Sinir Ağlarında En Çok Kullanılan Modeller	56
3.9. Özet	57
Bölüm 4. İLK YAPAY SİNİR AĞLARI	59
4.1. Tek Katmanlı Algılayıcılar (TKA)	59
4.2 Basit Algılayıcı Modeli (<i>Perseptron</i>)	61
4.2.1. Basit Algılayıcıların Yapısı	61
4.2.2. Basit Algılayıcı Öğrenme Kuralı	62
4.2.3. Basit Algılayıcı Öğrenmesine Bir Örnek	63
4.3. ADALINE/MADALINE Modeli	68
4.3.1. ADALINE Ünitesinin Öğrenme Kuralı	69
4.3.2. ADALINE Ünitesinin Öğrenmesine Bir Örnek	70
4.4. MADALİNE	73
4.5. Özet	73
4.6. Kaynakça	74
Bölüm 5. YAPAY SİNİR AĞI MODELİ (ÖĞRETMENLİ ÖĞRENME) ÇOK KATMANLI ALGILAYICI	75
5.1. Çok Katmanlı Algılayıcı (ÇKA)	75
5.2. ÇKA Modelinin Yapısı	76
5.3. ÇKA Ağının Öğrenme Kuralı	77
5.3.1. İleri Doğru Hesaplama	78
5.3.2. Geriye Doğru Hesaplama	78
5.4. ÇKA Ağının Çalışma Prosedürü	81
5.5. Ağın Eğitilmesi	82
5.6. XOR Probleminin Çözülmesi	85
5.7. ÇKA Ağının Performansının Ölçülmesi	90
5.8. ÇKA Ağının Öğrenmek Yerine Ezberlemesi	90
5.9. Bir ÇKA Ağının Oluşturulmasında Dikkat Edilmesi Gereken Bazı Önemli Noktalar	91
5.9.1. Örneklerin Seçilmesi	91
5.9.2. Girdi ve Çıktıların Gösteriminin Belirlenmesi	94
5.9.2.1. Girdi Değerlerinin Nümerik Gösterimi	94
5.9.2.2. Çıktıların Nümerik Gösterimi	97
5.9.3. Başlangıç Değerlerinin Atanması	98
5.9.4. Öğrenme Katsayısı ve Momentum Katsayılarının Belirlenmesi	99
5.9.5. Örneklerin Ağa Sunulması Şekli	100

5.9.6. Ağırlıkların Değiştirilmesi Zamanı	100
5.9.7. Örneklerin Değerlerinin Ölçeklendirilmesi (<i>Scaling</i>)	101
5.9.7.1. Girdilerin Ölçeklendirilmesi	101
5.9.7.1.1. Çıktıların Ölçeklendirilmesi	102
5.9.8. Durdurma Kriterleri	103
5.9.9. Ara Katman Sayısı ve Proses Elemanlarının Sayısının Belirlenmesi	104
5.10. Ağların Büyütülmesi veya Budanması	104
5.11. ÇKA Ağının Uygulama Alanları	105
5.12. Çok Katmanlı Algılayıcı Bir Örnek Uygulama (Endüstriyel Uygulama)	107
5.12.1. Problemin Tanımlanması	107
5.12.2. Öğrenme Setinin Oluşturulması	108
5.12.3. ÇKA Ağının Oluşturulması	109
5.12.4. ÇKA Ağının Eğitilmesi	110
5.12.5. Sonuçların Tartışılması	111
5.13. Özet	112
5.14. Kaynakça	113
Bölüm 6. YAPAY SİNİR AĞI MODELİ (DESTEKLEYİCİ ÖĞRENME)	115
- LVQ MODELİ	
6.1. LVQ Ağının Özellikleri	115
6.2. LVQ Ağının Yapısı	116
6.3. LVQ Ağının Çalışma Prosedürü	117
6.3.1. LVQ Ağının Öğrenme Kuralı	118
6.3.2. LVQ Ağının Eğitilmesi	120
6.4. LVQ2 Ağı	122
6.5. Cezalandırma Mekanizmalı LVQ	123
6.6. LVQ-X Modeli	124
6.7. LVQ Ağının Uygulama Alanları	125
6.8. LVQ – Endüstriyel Bir Örnek Uygulama (Örüntü Tanıma)	125
6.8.1. Problemin Tanımlanması	126
6.8.2. Öğrenme Setinin Oluşturulması	129
6.8.2.1. Normal Şeklin Üretilmesi	129
6.8.2.2. Artan veya Azalan Trendin Üretilmesi	129
6.8.2.3. Yukarı veya Aşağı Doğru Kaymanın Üretilmesi	130
6.8.2.4. Periyodik Şeklin Üretilmesi	130
6.8.3. LVQ Ağının Oluşturulması	130
6.8.4. LVQ Ağının Eğitilmesi	132
6.8.5. Sonuçların Tartışılması	133
6.9. Özet	134
6.10. Kaynakça	135

Bölüm 7. YAPAY SİNİR AĞI MODELİ (ÖĞRETMENSİZ ÖĞRENME) ADAPTİF REZONANS TEORİ (ART) AĞLARI	137
7.1. Hafıza (Bellek) Kavramı	137
7.2. ART Ağları	138
7.3. ART Ağlarının Diğer Yapay Sinir Ağlarından Farkları	139
7.4. ART Ağlarının Yapısı	141
7.5. ART Ağlarının Çalışma Prensibi	141
7.6. ART1 Ağı	144
7.6.1. ART 1 Ağının Eğitilmesi ve Öğrenmesi	145
7.7. ART2 Ağı	147
7.7.1. ART2 Ağının Yapısı	148
7.7.2. ART2 Ağının Çalışma Prensibi	149
7.7.3. ART2 Ağının Öğrenme Kuralı	150
7.8. ART Ağlarında Etiketlendirme	153
7.9. ART1 - Bir Örnek Uygulama -Grup Teknolojisine Dayalı İmalat Uygulaması	154
7.9.1. Problemin Tanımlanması	154
7.9.2. Problemin Modelinin Oluşturulması	155
7.9.3. Oluşturulan Ağın Eğitilmesi	156
7.9.4. Sonuçların Tartışılması	161
7.10. Özet	161
7.11. Kaynakça	162
Bölüm 8. GERİ DÖNÜŞÜMLÜ (RECURRENT) AĞLAR (ELMAN AĞI) VE DİĞER YAPAY SİNİR AĞI MODELLERİ	165
8.1. Geri Dönüşümlü Ağlar	165
8.1.1. Elman Ağı ve Yapısı	166
8.1.2. Elman Ağının Öğrenmesi	168
8.1.3. Geri Dönüşümlü Ağların Uygulama Alanları	170
8.2. Diğer Yapay Sinir Ağı Modelleri ve Son Araştırmalar	170
8.2.1. Diğer Yapay Sinir Ağı Modelleri	170
8.2.2. Hopfield Ağı	170
8.2.2.1. Kesikli Hopfield Ağı	171
8.2.2.2. Sürekli Hopfield Ağı	173
8.2.3. Counterpropagation Ağı	173
8.2.3.1. Kohonen Katmanının Çalışması	174
8.2.3.2. Grosberg Katmanının Çalışması	175
8.2.3.3. Kohonen Katmanının Eğitilmesi	175
8.2.3.4. Grosberg Katmanının Eğitilmesi	176
8.2.4. Cognitron ve Neocognitron Ağları	176
8.2.4.1. Cognitron Ağı	176
8.2.4.2. Cognitronun Eğitilmesi	179
8.2.4.3. Neocognitron	180

8.2.5. SOM	180
8.2.5.1. SOM Ağının Eğitilmesi	182
8.2.6. Karma ve Bileşik Ağlar	183
8.3. Özet	184
8.4. Kaynakça	185
Bölüm 9. BİLEŞİK YAPAY SİNİR AĞLARI	187
9.1. Birleşik Ağların Yapısı	188
9.2. Bileşik Ağların Eğitilmesi ve Test Edilmesi	189
9.3. Ortak Karar Verme Modülü	190
9.4. Bileşik Ağların Uygulanması	192
9.5. Karma sistemler (Uzman sistem + Yapay Sinir ağları)	194
9.6. Özet	195
9.7. Kaynakça	195
Bölüm 10. YAPAY SİNİR AĞLARI DONANIMI	197
10.1. Dijital Yapay Sinir Ağı Donanımları	198
10.2. Analog Yapay Sinir Ağı Donanımları	200
10.2.1. Analog Sistemlerin Avantajları ve Dezavantajları	201
10.3. Karma Tasarımlar	201
10.4. Yapay Sinir Ağı Donanımlarının Performanslarının Ölçülmesi ve Karşılaştırılmaları	202
10.5. Özet	202
Bölüm 11. YAPAY SİNİR AĞLARININ UYGULAMALARINA GENEL BİR BAKIŞ	203
11.1. Yapay Sinir Ağlarının Uygulama Alanları	203
11.1.1. Endüstriyel Uygulamalar	204
11.1.2. Finansal Uygulamalar	205
11.1.3. Askeri Uygulamalar	205
11.1.4. Sağlık Uygulamaları	206
11.1.5. Diğer Alanlar	206
11.2. Herhangi Bir Uygulama İçin Ağ Seçimi	207
11.3. Yapay Sinir Ağı Uygulamalarının Avantajları	207
11.4. Yapay Sinir Ağı Uygulamalarının Dezavantajları	208
11.5. Yapay Sinir Ağı Simulatörleri	209
11.6. Yapay Sinir Ağları Bilgi Kaynakları	210
11.7. Özet	210
KAYNAKÇA	211
DİZİN	231

Papatya Yayıncılık Eğitim

bilgi@papatya.gen.tr

ÖNSÖZ

Çağdaş dünyada bilgisayarlar ve bilgisayar sistemleri insan hayatının vazgeçilmez bir parçası haline gelmiştir. Elimizdeki cep telefonlarından, mutfaklardaki buzdolaplarına kadar birçok alet bilgisayar sistemi ile çalışmaktadır. İş dünyasından kamu işlerine, çevre ve sağlık organizasyonlarından askeri sistemlere kadar hemen hemen her alanda bilgisayarlardan yararlanmak olağan hale gelmiştir. Bunun aksini düşünmek bile teknolojinin nimetlerini hiçe saymak olarak görülmektedir. Teknolojinin gelişmesi izlendiğinde önceleri sadece elektronik veri transferi yapmak ve karmaşık hesaplamaları gerçekleştirmek üzere geliştirilen bilgisayarların zaman içerisinde büyük miktarlardaki verileri filtreleyerek özetleyebilen ve mevcut bilgileri kullanarak olaylar hakkında yorumlar yapabilen nitelikler kazandığı görülmektedir.

Bu çalışmaların temeline bakıldığında aslında bilgisayarlar, yüzyıllar boyunca insan beyninin nasıl çalıştığının merak edilmesi sonucunda ortaya çıkan ilkel hesap makinelerinin gelişmiş şekilleridir. Teknoloji geliştikçe insanlar bilgisayarların işlemleri hızlı yapmak gibi bazı özellikleri bu temel düşüncenin üstünü örtmüş ve insanlar teknolojinin geliştirilmesini teknolojiden elde edecekleri yarara bağlamışlardır. Bazı araştırmacılar ise ısrarla çalışmalarını insanın davranışlarının modellenmesi yolunda devam ettirmişler ve yapay zeka bilimi başta olmak üzere oldukça önemli gelişmeleri ortaya çıkartmışlardır.

1980’li yılların başlarına gelindiğinde aslında bilgisayar teknolojisinin günümüz ile kıyaslanamaz bir durumda olduğunu görüyoruz. O zamanlarda, insan beyninin bir benzeri yapılabilir mi? İnsan gibi davranabilen bir robot oluşturulabilir mi? Bilgisayarlar düşünebilirler mi? Olayları öğrenebilirler mi? vb. gibi soruların cevapları henüz bulunmamıştı. Aslında bu tür sorular yıllardır sürekli sorulmaktaydı. Sorulmaya da devam edilmiş ve sonuç olarak günümüzde bu soruların bazıları kısmen de olsa cevaplandırılmıştır. Hepsinin cevabı bulunamamıştır ama artık bilgisayarlar öğrenebilmektedir.

Diğer bir deyişle artık bilgisayarlar hem olaylar ile ilgili bilgileri toplayabilmekte, olaylar hakkında kararlar verebilmekte hem de olaylar arasındaki ilişkileri öğrenebilmektedir. Matematiksel olarak formülasyonu kurulamayan ve çözülmesi mümkün olmayan problemler bile sezgisel yöntemler yolu ile bilgisayarlar tarafından çözülebilmektedir. Bilgisayarları bu özellikler ile donatan ve bu yeteneklerinin gelişmesini sağlayan çalışmalar “yapay zeka” çalışmaları olarak bilinmektedir. İlk defa 1950’li yıllarda ortaya atılan yapay zeka terimi zaman içinde oldukça yoğun ilgi görmüş ve 40-50 yıllık bir zaman diliminde hayatın vazgeçilmez parçası olan sistemlerin doğmasına neden olmuştur. Yapay sinir ağları yapay zeka çalışmalarının da ivmesini artırmıştır. Bu teknoloji özellikle makine öğrenmesini sağlayan ve önemli gelişmelerin habercisi bir teknoloji olarak görülmüştür. Aslında sanayi toplumun bitip bilgi toplumunun başlamasına neden olan unsurlardan birisi yapay sinir ağları olmuştur.

Yapay sinir ağları, olayların örneklerine bakmakta onlardan ilgili olaya hakkında genellemeler yapmakta, bilgiler toplamakta ve daha sonra hiç görmediği örnekler ile karışılışınca öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilmektedir. Bundan 15-20 yıl önce böyle bir şeyin olacağını düşünmek bile mümkün değildi. O zaman bilgisayarlar öğrenebilecek denilse idi bu hayal ürünü olarak görülürdü. Fakat zaman içinde gelişmeler

bunun bir hayal değil gerçek olabileceğini gösterdi. Gelecekte de bugün için hayal olarak görebileceğim bir çok yenilikler ortaya çıkacaktır.

1990'lı yıllardan beri bilgisayarların öğrenmesini sağlayan Yapay Sinir Ağları teknolojisinde oldukça hızlı bir gelişme görüldü. Bu teknoloji, kısa zamanda araştırmacıların dikkatlerini üzerine çeken bir bilim dalı olmayı başardı ve çalışmalar laboratuarlardan çıkarak günlük hayatın bir parçası haline gelmeye başladı. Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemler olduklarından hem yeni gelişmelere neden oluyor hem de nasıl çalıştığı bilinmeyen insan beyni hakkında yapılan araştırmalara da önemli katkılar sağlıyordu. Kısa bir zaman içinde,

Çok sayıda yapay sinir ağı modeli geliştirilmiş ve sayısız uygulama ortaya çıkmıştır. Gelişmeler bu sistemlerin gelecekte daha fazla insan hayatına gireceğini göstermektedir. Bu çalışmalar aslında insan beyninin nasıl çalıştığı ve öğrenme olayını nasıl gerçekleştirdiğini merak etme sonucunda ortaya çıkmıştır. İnsan beyninin nasıl çalıştığı günümüzde de henüz bilinmemektedir. Fakat yapılan çalışmalar ile bilgisayarların öğrenebildikleri ve başarılı sonuçlar ürettikleri görülmektedir. Özellikle çok sayıda bilginin değerlendirilmesini gerektiren olaylarda bu sistemler etkin olarak kullanılmaktadır. Endüstriyel hayattan finansal hayata, tıp biliminden askeri sistemlere kadar bir çok alanda uygulamalar görülmektedir. Bu uygulamalarda elde edilen başarılar hem yapay sinir ağlarının önemini artırmakta hem de bu sistemlere olan ilgiyi artırmaktadır. Her geçen gün bu kadar önemli olmasına rağmen Yapay sinir ağlarını ayrıntılı olarak anlatan Türkçe yazılmış bir eser olmadığı görülmüş ve bu amaçlar bu kitap yazılmıştır. Kitap içerisinde hem yapay sinir ağlarının felsefesi anlatılmış hem de bu teknolojinin teknik ayrıntıları verilmiştir. Yapay sinir ağlarında genel olarak ağı ne öğrenmesi gerektiğini söyleyen bir öğretmenin olup olmamasına göre değişen öğrenme stratejileri vardır. Kitabın içerisinde bu stratejilerin her birisi ile ilgili olarak bir yapay sinir ağının nasıl oluşturulabileceği, nasıl eğitileceği, nasıl test edileceği anlatılmıştır. Bu konuda okuyucunun dikkat etmesi gereken konularda açıklanmıştır. Bunun yanı sıra günümüzde en çok kullanılan ve özellikle endüstriyel ve sosyal hayatta kendisini göstermiş olan yapay sinir ağları da kısa kısa tanıtılmış ve özellikleri belirtilmiştir. Yapay sinir ağlarının uygulamaları genel olarak gözden geçirilmiş ve donanım olarak piyasa da ticari olarak geliştirilmiş sistemlerden örnekler verilerek bu teknolojinin sadece bir yazılım teknolojisi olmadığı aynı zamanda özel donanımlarında geliştirildiğine dikkatler çekilmiştir. Okuyucu bu kitabı okuyunca sadece kitapta anlatılan ağları öğrenmeyecek aynı zamanda diğer ağlar ile ilgili bilgileri bulabileceği kaynaklara da ulaşacaktır.

Kitabın okuyuculara yardımcı olmasını umarım.

Prof. Dr. Ercan Öztemel
Mart 2003 - İstanbul

YAPAY ZEKA VE MAKİNE ÖĞRENMESİNE GENEL BAKIŞ

Yapay sinir ağları yapay zeka biliminin altında araştırmacıların çok yoğun ilgi gösterdikleri bir araştırma alanıdır. Bilgisayarların öğrenmesine yönelik çalışmaları kapsamaktadır. Bu bölümde öncelikle yapay zeka bilimine genel bir giriş yapılarak bilgisayarların karar verme ve öğrenme niteliklerine dikkatler çekilecektir.

1.8. Özet

Yapay zeka teknolojisi her geçen gün daha fazla gelişmektedir. Yeni ürünler ortaya çıkmakta ve daha çok günlük hayatta kendisini göstermektedir. Otomasyon sistemleri de yapay zeka teknolojisi ile donatılarak bilgisayarın karar verme gücünden faydalanılmaktadır. Her geçen gün daha yeni ticari sistemler ortaya çıkmakta ve sistemlerin fonksiyonel özellikleri artmaktadır. Yapay zeka teknolojilerinden özellikle;

- **Uzman sistemler:** Bir uzmanın problemleri çözdüğü gibi problemlere çözümler üreten sistemlerdir. Uzmanlık bilgisi ile donatılırlar. Çıkarım mekanizmaları bilgiler arasındaki ilişkileri kurarak kararlar verirler.
- **Yapay sinir ağları:** Örneklerden olaylar arasındaki ilişkileri öğrenerek daha sonra hiçi görmediği örnekler hakkında öğrendikleri bilgileri kullanarak karar veren sistemlerdir.
- **Genetik algoritmalar:** Geleneksel optimizasyon teknolojisi ile çözülemeyen problemleri çözmek üzere geliştirilmişlerdir. Problemlerin çözümlerini birleştirerek daha iyi çözümler üretmek felsefesine dayanmaktadır.
- **Bulanık önermeler mantığı:** Belirsiz bilgileri işleyebilme ve kesin rakamlar ile ifade edilemeyen durumlarda karar vermeyi kolaylaştıran bir teknolojidir.
- **Zeki etmenler:** değişik yapay zeka tekniklerini kullanabilen ve bağımsız olarak çalışabilen sistemlerdir. Esnek bir şekilde programlanmaktadır.

Bu teknolojiler günlük hayatta insanlara faydalı ürünlerin oluşmasına katkıda bulunmaktadır. Bunlardan yapay sinir ağları bilgisayarın öğrenmesini sağlamaktadır. Makine öğrenmesi zaman içinde davranışların iyileştirilmesi olarak tanımlanmaktadır. Değişik öğrenme paradigmaları geliştirilmiştir. Bu kitapta özellikle örneklerden öğ-

renme konusu anlatılacaktır. Bu öğrenme paradigmaları 3 strateji üzerine kurulmuştur. Bunlar;

- öğretmenli öğrenme
- destekli öğrenme
- öğretmensiz öğrenme.

Bu stratejilere dayanarak geliştirilmiş öğrenme kuralları vardır. Bu kuralların bazıları çevrimiçi bazıları ise çevrimdışı öğrenme yaparlar. Kitap içinde bu tür öğrenme gerçekleştirebilen kuralların örnekleri ayrıntılı olarak açıklanacaktır. Özellikle *delta* kuralı, *Hopfield* kuralı, *Kohonen* kuralı ve *Grosberg* kuralı ilerde açıklanacaktır.

YAPAY SİNİR AĞLARINA GİRİŞ

Bir önceki bölümde Yapay Zeka bilimi ve Makine Öğrenmesi çalışmaları çok genel bir şekilde anlatılmıştır. Öğrenmeye ve yapay sinir ağlarına dikkatler çekilmiştir. Bu bölümde ise yapay sinir ağları genel olarak tanıtılmakta temel elemanları açıklanmaktadır.

2.7. Özet

Yapay Sinir ağları insan beyninin em temel özelliği olan öğrenme fonksiyonunu gerçekleştiren bilgisayar sistemleridir. Öğrenme işlemini örnekler yardımı ile gerçekleştirirler. Bu ağlar birbirine bağlı proses elemanlarından (yapay sinir hücrelerinden) oluşur. Her bağlantının bir ağırlık değeri vardır. Yapay sinir ağının sahip olduğu bilgi bu ağırlık değerlerinde saklı olup ağa yayılmıştır.

Yapay sinir ağları bilinen hesaplama yöntemlerinden farklı bir hesaplama yöntemi önermektedir. Bulundukları ortama uyum sağlayan, adaptif, eksik bilgi ile çalışabilen, belirsizlikler altında karar verebilen, hatalara karşı toleranslı olan bu hesaplama yönteminin hayatın hemen hemen her alanında başarılı uygulamalarını görmek mümkündür. Oluşturulacak olan ağın yapısının belirlenmesinde, ağ parametrelerinin seçiminde, belirli bir standardın olmaması, problemlerin sadece nümerik bilgiler ile gösterilebilmesi, eğitimin nasıl bitirileceğinin bilinmemesi ve ağın davranışlarını açıklayamamasına rağmen bu ağlara olan ilgi her geçen gün artmaktadır. Özellikle, sınıflandırma, örüntü tanıma, sinyal filtreleme, veri sıkıştırma ve optimizasyon çalışmalarında yapay sinir ağları en güçlü teknikler arasında sayılabilirler. Veri madenciliği, optik karakter taşıma, optimum rota belirleme, parmak izi tanıma, malzeme analizi, iş çizelgelemesi ve kalite kontrol, tıbbi analizler gibi bir çok alanda günlük hayatımızda göreceğimiz başarılı örneklerine rastlamak mümkündür.

Yapay sinir ağlarının tarihsel gelişimine bakıldığında ise 1970 yılının bir dönüm noktası olduğu görülmektedir. Bu tarihten önce bir çok araştırmanın yapıldığı ve 1969 yılında XOR probleminin çözülememesi nedeni ile araştırmaların durduğu görülmektedir. 1970 yılından sonra sınırlı sayıda araştırmacının çalışmalarını sürdürmeleri ve XOR problemini çözmeleri sonucunda yapay sinir ağlarına olan ilgi yeniden alevlenmiştir. İzleyen 10 yıl içinde birbirinden farklı 30 civarından yeni model geliştirildi. Aynı zamanda çalışmalar laboratuarlardan çıkarak günlük hayatta kullanılan sistemler haline geldi. Bu çalışmalar hem yapay zeka hem de donanım teknolojisindeki gelişmeler ile de desteklenmiştir. Artık bilgisayarlarında öğrenebileceğini herkes kabul etmekte ve bu teknolojiyen faydalanmak istemektedir.

YAPAY SİNİR AĞLARININ YAPISI VE TEMEL ELEMANLARI

Önceki bölümlerde yapay zeka, makine öğrenmesi ve yapay sinir ağlarına genel bir giriş yapılmıştır. Bu bölümde ise yapay sinir ağlarının yapısı ve temel elemanları açıklanacaktır. Daha önce geliştirildiği gibi, yapay sinir ağları biyolojik sinir sisteminden esinlenerek geliştirilmiştir. O nedenle öncelikle biyolojik sinir sistemine bir göz atmakta yarar vardır. Sinir sistemi birbiri ile iletişim halinde olan sinir hücrelerinden oluşmaktadır. Aşağıda bir sinir hücresinin yapısı açıklanmıştır.

3.9. Özet

Yapay sinir ağları biyolojik sinir sisteminden etkilenerek geliştirilmiştir. Biyolojik sinir hücreleri birbirleri ile *synapsler* vasıtası ile iletişim kurarlar. Bir sinir hücresi işlediği bilgileri *axon*'ları yolu ile diğer hücelere gönderirler. Benzer şekilde yapay sinir hücreleri dışarıdan gelen bilgileri bir toplama fonksiyonu ile toplar ve aktivasyon fonksiyonundan geçirek çıktıyı üretip ağıın bağlantılarının üzerinden diğer hücelere (proses elemanlarına) gönderir. Değişik toplama ve aktivasyon fonksiyonları vardır. Yapay sinir ağlarını birbirlerine bağlayan bağlantıların değerlerine ağırlık değerleri denmektedir. Proses elemanları birbirlerine paralel olarak 3 katman halinde bir araya gelerek bir ağı oluştururlar. Bunlar;

- Girdi katmanı
- Ara katmanlar
- Çıktı katmanı

Bilgiler ağı girdi katmanından iletilir. Ara katmanlarda işlenerek oradan çıktı katmanına gönderilirler. Bilgi işlemekten kasıt ağı gelen bilgilerin ağıın ağırlık değerleri kullanılarak çıktıya dönüştürülmesidir. Ağıın girdiler için doğru çıktıları üretebilmesi için ağırlıkların doğru değerlerinin olması gerekmektedir. Doğru ağırlıkların bulunması işlemine ağıın eğitilmesi denmektedir. Bu değerler başlangıçta rasgele atanırlar. Daha sonra eğitim sırasında her örnek ağı gösterildiğinde ağıın öğrenme kuralına göre ağırlıklar değiştirilir. Daha sonra başka bir örnek ağı sunulur ağırlıklar yine değiştirilir ve en doğru değerleri bulunmaya çalışılır. Bu işlemler ağı eğitim setindeki örneklerin tamamı için doğru çıktıları üretinceye kadar tekrarlanır. Bu sağlandıktan sonra

Yapay Sinir Ağları

test setindeki örnekler ağa gösterilir. Eğer ağ test setindeki örneklere doğru cevaplar verirse ağ eğitilmiş kabul edilmektedir. Ağın ağırlıkları belirlendikten sonra her bir ağırlığın ne anlama geldiği bilinmemektedir. O nedenle yapay sinir ağlarına “**kara kutu**” yakıştırması yapılmaktadır. Ağırlıkların tek tek ne anlama geldikleri bilinmemekle birlikte ağın girdiler hakkındaki kararını bu ağırlıkları kullanarak vermesi, ağın zekasının bu ağırlıklarda saklandığı söylenebilir. Ağın bir olayı öğrenmesi o olay için en doğru yapay sinir ağı modelini seçmekle mümkündür. Şu ana kadar bir çok yapay sinir ağı modeli geliştirilmiştir. Bir yapay sinir ağının modelini şu bilgiler karakterize etmektedir.

- Ağın topolojisi
- Kullanılan toplama fonksiyonu
- Kullanılan aktivasyon fonksiyonu
- Öğrenme stratejisi
- Öğrenme kuralı

Geliştirilen modeller arasında en yaygın olarak kullanılanları, tek ve çok katmanlı algılayıcılar, LVQ, ART ağları, SOM, Elman ağı gibi ağlardır. Bu modeller ilerideki bölümlerde ayrıntılı olarak anlatılacaktır.

İLK YAPAY SİNİR AĞLARI

Yapay sinir ağlarına ve proses elemanlarının yapısına genel bir bakış yaptıktan sonra ilk yapay sinir ağı çalışmaları ve geliştirilen ilk modeller bu bölümde açıklanacaktır. Bu kapsamda tek katmanlı algılayıcılar, *Perceptron* ve ADALINE/MADALINE modellerinin yapısı ve öğrenme kuralları ayrıntılı olarak açıklanacaktır. Bu modeller daha sonra geliştirilen modellere temel oluşturduklarından önemlidir.

4.5. Özet

Yapay sinir ağları ile ilgili çalışmaları tek katmanlı algılayıcılar ile başlamıştır. Bu algılayıcıların en önemli özelliği problem uzayını bir doğru veya bir düzlem ile sınıflara ayırmalarıdır. Problemin girdileri ağırlıklar ile çarpılıp toplandıktan sonra elde edilen değer bir eşik değerinden büyük veya küçük olmasına göre girdinin sınıfı belirlenir. Sınıflar 1 veya -1 rakamları (bazen 1 ve 0 rakamları) ile gösterilir. Öğrenme sırasında hem ağırlıklar hem de eşik değeri ünitelerinin ağırlık değeri değiştirilir. Eşik değeri ünitelerinin çıktısı sabit olup 1'dir. Bilinen en nemli tek katmanlı algılayıcılar şunlardır.

- Basit tek katmanlı algılayıcılar (*perceptron*)
- ADALINE/MADALINE üniteleri

Bu modelleri birbirinden ayıran tek şey öğrenme kuralıdır.

Basit tek katmanlı algılayıcılarda ağırlıklar değiştirilir iken girdilerin öğrenme katsayısı (λ) denilen bir sabit ile çarpılıp ağırlıklara eklenmesi veya çıkartılması ile gerçekleştirilir. Ağa sunulan girdilere dayanarak üretilen çıktının değerine göre ağırlıklar artırılır veya azaltılır.

ADALINE ünitesinde ise ağırlıkların değiştirilmesi beklenen çıktı ile gerçekleşen çıktı arasındaki farka dayanarak gerçekleştirilir. Aradaki bu farka hata denirse; yeni ağırlık değerleri bu hatanın bir öğrenme katsayısı (α) ile girdilerin çarpılmasının sonucu elde edilen değerin eski ağırlıklara eklenmesi ile belirlenir.

ADALINE üniteleri bir araya gelerek MADALINE ağının oluştururlar. MADALINE ağının öğrenme kuralı ADALINE ünitesi ile aynıdır. MADALINE ağında ADALINE üniteleri birbirlerine AND veya OR operatörleri kullanılarak bağlanırlar. Bu operatörler klasik mantıkta kullanıldıkları şekilde kullanılırlar. Her ADALINE çıktısı bu operatörler yolu ile MADALINE ağının çıktılarına dönüştürülürler.

Tek katmanlı algılayıcıların en önemli problemi doğrusal olmayan olayları öğrenememeleridir. O nedenle bunlar geliştirilmiş ve yeni modeller oluşturulmuştur. İlerideki bölümlerde bunlara örnekler verilecektir.

YAPAY SİNİR AĞI MODELİ (ÖĞRETMENLİ ÖĞRENME) ÇOK KATMANLI ALGILAYICI

Bir önceki bölümde anlatılan yapay sinir ağlarının ilk modellerinin en temel özellikleri doğrusal olan olayları çözebilme yeteneklerine sahip olmalarıdır. Bu ağlar ile doğrusal olmayan ilişkiler öğrenilememektedir. Bu sorunu çözmek için çok katmanlı algılayıcılar geliştirilmiştir. Bu bölümde çok katmanlı algılayıcılar ayrıntılı olarak anlatılacaktır.

5.13. Özet

Yapay sinir ağlarının günümüzde en yaygın olarak kullanılan modeli çok katmanlı algılayıcı (ÇKA) ağlarıdır. Bu ağlar, özellikle mühendislik problemlerinin %95'ine çözüm üretebilecek nitelikte bir ağıdır. ÇKA ağları XOR problemini çözebilme için yapılan çalışmalar neticesinde ortaya çıkmıştır. Bu ağlar 3 katmandan oluşurlar

- **Girdi katmanı:** Dış dünyadan bilgileri alır. Bu katmanda herhangi bir bilgi işleme olmaz.
- **Ara katmanlar:** Girdi katmanından gelen bilgileri işlerler. Bir adet ara katman ile birçok problemi çözmek mümkündür. Eğer ağın öğrenmesi istenilen problemin girdi/çıkı arasındaki ilişkisi doğrusal olmaz ve karmaşıklık artarsa birden fazla sayıda ara katmanda kullanılabilir.
- **Çıktı katmanı:** Ara katmandan gelen bilgileri işleyerek ağa girdi katmanından sunulan girdi için ağın ürettiği çıktıyı bulur. Bu çıktı dış dünyaya iletilir.

Girdi ve çıktı katmanlarında kaç tane proses elemanının olması gerektiğine probleme bakılarak karar verilir. Ara katman sayısı ve her ara katmandaki proses elemanı sayısının kaç olması gerektiğini gösteren bir yöntem yoktur. Bu deneme yanılma yolu ile belirlenmektedir. Girdi katmanındaki proses elemanlarının her birisi ara katmandaki proses elemanlarının hepsine bağlıdır. Onlarda çıktı katmanındaki proses elemanlarının hepsine bağlıdır. Bilgi akışı girdi katmanından ara katmana oradan da çıktı katmanına ileri doğrudur.

ÇKA ağının eğitilmesi “genelleştirilmiş delta kuralı”na göre gerçekleşmektedir. ÇKA ağları öğretmenli öğrenme stratejileri kullandıklarından eğitim sırasında hem girdiler hem de o girdilere karşılık ağın üretmesi gereken çıktılar ağa gösterilirler. Kullanılan öğrenme kuralının felsefesi eğitim sırasında ağın ürettiği çıktılar ile üretmesi gereken

(beklenen) çıktılar arasındaki farkın (hatanın) ağırlıklarına dağıtılarak zaman içinde bu farkın en aza indirgenmesidir. Öğrenme sırasında önce girdiler ağına sunulur, bu girdilere karışıklık gelen çıktılar üretilir. Bu işleme ileri doğru hesaplama denir. Daha sonra üretilen çıktı ile beklenen çıktı karşılaştırılarak aradaki hata geriye doğru dağıtılarak ağırlıklar değiştirilirler. Buna da geriye doğru hesaplama denmektedir.

ÇKA ağlarının olayları öğrenmesini etkileyen faktörler şunlardır.

- Örneklerin seçilmesi
- Girdi ve çıktıların ağına sunulması
- Girdi ve çıktıların sayısal gösterimi
- Ağırlıkların başlangıç değerlerinin atanması
- Öğrenme ve momentum katsayılarının belirlenmesi
- Örneklerin ağına sunulması
- Ağırlıkların değiştirilme zamanları
- Girdi ve çıktıların ölçeklendirilmesi
- Durdurma kriterinin belirlenmesi
- Ağların büyütülmesi ve budanması

ÇKA ağlarının tasarımcıları bu faktörleri dikkatlice değerlendirmeli ve problemin çözümü için en uygun yaklaşımı kullanmalıdırlar. Bölüm içinde değişik yaklaşımlar örnekler ile anlatılmıştır.

ÇKA ağlarının eğitim performansını ölçmek için eğitim bittikten sonra ağına eğitim sırasında görmediği örnekler ağına gösterilerek bunlar hakkında ağına kararına bakılır. Eğer ağına görmediği örneklerle doğru cevaplar üretiyorsa o zaman performansı iyidir ve layığı öğrenmiştir denir.

ÇKA ağlarının mühendislik problemlerindeki başarılı uygulamaları dikkatleri üzerine çekmektedir. Özellikle;

- Sınıflama
- Tahmin etme
- Tanıma
- Yorumlama
- Teşhis etme

Konularında tıp biliminden finans dünyasına kadar bir çok alanda başarılı uygulamalar görülmüştür. Bölüm içinde Taguchi'nin kalite tasarım metoduna alternatif olarak geliştirilen bir ÇKA ağı tanıtılmıştır. Problemin tanıtılması ve ağına eğitilmesi sonucu Taguchi'nin yaklaşık %6 hata ile tahmin ettiği üretim kombinasyonunu ÇKA ağı %25 gibi çok küçük bir hata ile daha başarılı bir şekilde tahmin etmiştir. ÇKA ağının problem hakkında ön bilgi istememesi, doğrusal olmayan ilişkileri dikkate alması gibi yararlarının olduğu da görülmüştür; bu, geleneksel yöntemlere alternatif olacağını da göstermektedir.

YAPAY SİNİR AĞI MODELİ (DESTEKLEYİCİ ÖĞRENME) - LVQ MODELİ

Bu bölüme kadar özellikle öğretmenli öğrenme konusunda geliştirilmiş modeller tanıtılmıştır. O modellerde eğitim sırasında ağa hem girdi değerleri hem de o girdi değerleri için üretilcek çıktı değerinin ne olması gerektiği konusunda bilgiler verilmektedir. Bazı durumlarda ağa çıktının ne olduğunu vermek mümkün olamamaktadır; fakat, ağın üretmiş olduğu çıktının doğru veya yanlış olduğu belirtilebilmektedir. Destekleyici öğrenme olarak belirlenen bu yöntemi kullanan modellerin bir tanesi de doğrusal vektör parçalama modeli diyebileceğimiz LVQ (*Linear Vektör Quantization*) modelidir. Bu bölümde bu model ayrıntılarıyla ele alınmaktadır.

6.9. Özet

LVQ ağları destekli öğrenme stratejisini kullanırlar. Eğitim sırasında ağa sadece öğrenilmesi istenen girdiler verilmekte ve ağın çıktıyı kendisi üretmesi istenmektedir. Ağ çıktısını ürettikten sonra, ağa sunulan girdi vektörüne karşılık gelen ağın ürettiği çıktının doğru veya yanlış olup olmadığı söylenmektedir. LVQ ağının temel felsefesi ağa sunulan girdi vektörünü problem uzayını temsil eden referans vektörlerinden birisine haritalamaktır. LVQ ağı, 3 katmandan oluşmaktadır. Bunlar:

- Girdi katmanı
- *Kohonen* katmanı
- Çıktı katmanı

Girdi katmanındaki her eleman *Kohonen* katmanındaki her elemana bağlıdır. Girdi katmanından, *Kohonen* katmanına bağlantıların ağırlıkları bir referans vektörünü oluşturur. Öğrenme sırasında sadece bu referans vektörlerinin değerleri (ağırlık değerleri) değiştirilirler. Her iterasyonda sadece tek bir vektörün değerleri değiştirilir. Öğrenmenin başarısı ise bu vektörlerin başlangıç değerleri ile yakından ilgilidir. *Kohonen* katmanındaki elemanların her biri çıktı katmanındaki sadece tek bir elemana bağlıdır. *Kohonen* katmanı ile Çıktı katmanı arasındaki ağırlıklar sabit olup değerleri 1'dir. Bu ağırlıkların değerleri eğitim sırasında değiştirilmez. LVQ ağlarında öğrenme girdi vektörü ile referans vektörleri arasındaki öklid mesafesine dayanmaktadır. *Kohonen* katmanındaki her eleman bir referans vektörünü göstermekte olup birbirleri ile yarışırırlar. Öklid mesafesi en kısa olan eleman yarışmayı kazanır. Yarışmayı kazanan elemanın çıktısı 1 diğerleri ise 0 değerini alır. Yarışmayı kazanan çıktı elemanı ilgili gir-

dinin sınıfını gösterir. Eğer girdi doğru sınıflandırılmış ise ilgili referans vektörü girdi vektörüne yaklaştırılır. Aksi halde ise uzaklaştırılır. Yaklaştırma ve uzaklaştırma öğrenme katsayısı ile gerçekleştirilmektedir. LVQ ağıının en önemli problemi aynı vektörün çok sık kazanması ve ağıın öğrenme performansının düşük olmasıdır. Bu sorun zamanla öğrenmenin ters yönde öğrenmemeye dönüşmesine neden olmaktadır. Bunu önlemek için öğrenme katsayısı zaman içinde azaltılarak sıfır değerine kadar düşürülmesi ve öğrenme tamamlanınca sıfır değerini alarak öğrenmeyi durdurması sağlanmaktadır. Bu sorunu çözmek için yeterli olmadığından, öğrenme algoritması da geliştirilmiştir. LVQ2 öğrenme yöntemi sınıflar arasında kalan örnekleri sınıflandıracak yeteneğe sahiptir. Bunun yanında çok kazanan proses elemanlarını cezalandırarak diğer proses elemanlarında şans verilmesi için başka bir yöntem önerilmiştir. Diğer bir yöntem de ise, eğitim sırasında her iterasyonda birden fazla referans vektörünün ağırlıklarını değiştirmek ve yanlış sınıflandırılan örnekler referans vektörlerinden uzaklaştırılırken doğru sınıfın bir örneği referans vektörüne yaklaştırılmaktadır. LVQ-X adı verilen bu yöntem hem başlangıç değerlerine bağılılığı ortadan kaldırmış, hem öğrenme %100 gerçekleştirilmiş, hem eğitim performansı yükselmiş hem de öğrenmenin hızı artmıştır. Bu avantajlar XPC adı verilen zeki istatistiksel kalite kontrol sisteminde gerçekleştirilen örnek uygulamada LVQ-X algoritması, sadece diğer LVQ ağılarından değil aynı zamanda hem ÇKA ağıından hem de geleneksel istatistiksel yöntemlerden daha başarılı bir öğrenme gerçekleştirmiştir.

YAPAY SİNİR AĞI MODELİ (ÖĞRETMENSİZ ÖĞRENME) ADAPTİF REZONANS TEORİ (ART) AĞLARI

Bu bölüme kadar öğretmenli ve destekli öğrenmeye dayalı ağlar örneklerle ele alındı. Bu bölümde ise öğretmensiz öğrenmeye dayalı ART ağlarına değinilecektir. Bu konuyu iyi anlamak için öncelikle hafıza ve bilgilerin hafızada saklanması kavramları açıklanacaktır. Çünkü burada ağ dışarıdan herhangi bir destek almaksızın örneklere bakarak bilgileri kendisi keşfetmek ve hafızasında saklamak durumundadır.

7.10. Özet

Bu bölümde öğretmensiz öğrenme stratejisi kullanarak öğrenen ART ağları tanıtılmıştır. Bu ağların en önemli özellikleri gerçek zamanlı çalışabilmeleri ve çevrimiçi (*on-line*) öğrenebilmeleridir. Yeni durumlara adapte olabilmekte ART ağları oldukça güçlüdürler. Bunu sağlayabilmek için bir taraftan öğrenirken bir taraftan da unutulmaktadır. Bir ART ağı, gösterim katmanı (F1) ve kategori katmanı (F2) olmak üzere iki katmandan oluşmaktadır. Bunların yanında, ağa sunulan girdilerin sınıflandırılmasını durdurmakta yeni bir kategori oluşturmaya yardım eden oryantasyon modülü vardır. F1 ve F2 katmanları arasında hem aşağıdan yukarı hem de yukarıdan aşağı ağırlık vektörü vardır. Eğitim sırasında bu ağırlıklar örneklere bakılarak değiştirilirler. Girdiler F1 katmanından ağa sunulur ve yukarı doğru ağırlıklar ile F2 katmanından çıktı değerleri hesaplanır. F2 katmanında en yüksek çıktı değerini oluşturan proses elemanı yarışmayı kazanan proses elemanı olarak 1 değerini diğerleri ise 0 değerini alır. Bu elemana bağlı ağırlıklar değiştirilir. Kazanan elemanın ilgili girdi vektörünün sınıfını göstermesi için ona bağlı hafızadaki vektör ile girdi vektörünün birbirine benzermesi gerekmektedir. Bu benzerliği benzerlik katsayısı denilen bir katsayı ile karar verilir. Eğer iki vektör birbirine benzer bulunursa girdi vektörü o sınıfın elemanı sayılır ve ağırlıklar girdi vektörüne göre güncellenir. Arada benzerlik olmaz ise o zaman oryantasyon sistemi o girdi vektörü için yeni bir sınıf oluşturur. Bu nedenle bir ART ağında örnek sayısı kadar sınıf sayısı oluşturulabilir. Değişik ART ağları geliştirilmiştir. ART1 ağı geliştirilmiş ilk ART ağıdır. Bu ağ sadece ikili (*binary*) değerlerden oluşan girdi vektörlerini kabul eder. ART2 ağları ise sürekli değerleri de kabul etmektedirler. Benzer şekilde ART3, Fuzzy ART, ARTMAP gibi başka modellerde

geliştirilmiştir. Bu modellerin eğitim performansları benzetim katsayısı ile yakından ilgilidir. Bu katsayının küçük olması sınıf sayısını azaltmakta, büyük olması ise sınıf sayısını artırmaktadır. Çünkü sayının büyük olması daha fazla benzerlik istenmesidir. İstenilen benzerlik düzeyi yakalanamayınca da yeni sınıflar oluşturulmaktadır. ART ağları endüstriyel problemlerde özellikle sınıflandırma amaçlı kullanılmakta ve oluşturulan etiketlendirme mekanizması ile sorunlara çözümlere önerilebilmektedir. Grup teknolojisi gibi makine hücrelerinin belirlenmesinde de geleneksel yöntemlerden daha etkili çözümler üretebilmektedirler.

Bu ağlardan özellikle ART2 ağının en önemli sorunlarından birisi birçok parametreyi kullanıcının belirlemesinin gerekmesidir. Bunlar ise ancak uzun denemeler ve deneyimler sonucunda doğru olarak belirlenebilmektedir.

GERİ DÖNÜŞÜMLÜ (RECURRENT) AĞLAR (ELMAN AĞI) VE DİĞER YAPAY SİNİR AĞI MODELLERİ

Daha önce ele alınan ağların en temel özelliklerinden birisi de ileri beslemeli ağlar olmalarıdır. Yani, bu ağlardaki proses elemanları çıktıların bir sonraki katmana veya dış dünyaya gönderirler. Bu elemanların çıktıların geri dönüşümü yoktur. Çıktıları proses elemanlarına geriye tekrar girdi olarak kullanılmamaktadır. Bu bölümde ise öncelikle geri dönüşü olan ağlar tanıtılacak ve bunlardan Elman ağı ayrıntılı olarak anlatılacaktır. Daha sonra yapay sinir ağının yaygın olarak kullanılan diğer modelleri kısa kısa açıklanacaktır.

8.3. Özet

Geri dönüşümlü ağlarda proses elemanlarının çıktıları sadece ileri doğru değil aynı zamanda geri doğru da gönderilmektedir. Genel olarak tam geri dönüşümlü ve kısmi geri dönüşümlü ağlardan söz etmek mümkündür. Elman ağı kısmi geri dönüşümlü ağlara verilecek en güzel örnektir. *Elman* ağı bilinen ÇKA ağlarına benzer bir şekilde tasarlanmış ve Genelleştirilmiş Delta kuralına göre eğitilirler. Bu ağlarda ÇKA ağlarından farklı olarak Çıkarım elemanları denilen proses elemanları vardır. Bu elemanların görevi ara katman elemanlarının çıktılarını ağa tekrar girdi olarak göndermektir. Ağın çıktısının hesaplanması ile ilgili formüller bölüm içinde verilmiştir. Ara katman elemanlarını içerik elemanlarına bağlayan bağlantıların ağırlık değerleri sabit olup 1'e eşittir. O nedenle ağın eğitimi sırasında beklenen çıktı ile gerçekleşen çıktı arasındaki hatanın ağa yayılmasında bu bağlantılar dikkate alınmadıklarından ÇKA ağının öğrenmesi aynı şekilde burada da uygulanabilmektedir.

Günümüzde yaygın olarak kullanılan diğer ağlara örnekler ise şunlardır:

- *Hopfield* ağı
- *Conterpropagation* ağı
- *Cognition* ve *Neocognition*
- SOM ağı

Hopfield ağının en temel özelliği proses elemanlarının hepsinin birbirine bağlı olmasıdır. Ağ bağlantı değerleri bir enerji fonksiyonu olarak saklanmaktadır. İki türlü model vardır. Kesikli ve sürekli *Hopfield* ağları. Bu ağlar özellikle geleneksel yöntemler ile çözülmesi zor optimizasyon problemlerinin çözülmesinde kullanılabilirler.

Counterpropagation ağı ise *Kohonen* ve *Grosberg* öğrenme kurallarının birleştirilmesi ile oluşturulmuş bir ağıdır. Her iki öğrenme kuralında avantajlarını bir arada bulunmaktadır. Bu ağlarda özellikle şekil tanıma problemlerinde başarılı bir şekilde kullanılabilirler.

Cognitron ve *neocognitron* ağları ise daha çok insan beyninin görsel sisteminin görevini üstlenmek üzere geliştirilmiş ağlardır. Bu ağlarda iki katmandan oluşmaktadır. Birinci katman bağlantı alanları ikinci katman ise yarışma alanlarına bölünmüştür. Bu ağlarda uyarıcı ve men edici olmak üzere iki tür proses elemanı vardır. Bir elemanın çıktısı kendisine gelen uyarıcı ve men edici sinyallere göre belirlenmektedir. Bu ağlarda daha çok tanıma problemleri için kullanılmaktadır.

SOM öğretmensiz öğrenme yapabilen ve sınıflandırma problemlerinde başarılı bir şekilde uygulanan bir ağıdır. Ağın girdi ve çıktı katmanları vardır. Çıktı katmanındaki proses elemanları birbirleri ile yarışmakta ve yarışmayı kazanan eleman girdinin sınıfını göstermektedir. Ağın çıktı katmanı bir düzlem şeklinde düşünülmekte ve kazanan her proses elemanının komşularını gösteren komşuluk bölgesi oluşturulmaktadır. Komşuluk alanı içindeki bütün elemanlar kazanan eleman ile birlikte düşünülmektedir.

Bölüm içinde son olarak karma ve birleşik ağlara dikkatler çekilmiştir. Burada birden fazla ağın bir problemi çözebilmek için birlikte hareket etmeleri sağlanmaktadır. Bir sonraki bölümde özellikle bileşik ağların nasıl tasarlandığı ve problemlere nasıl çözümler ürettikleri gösterilecektir.

BİRLEŞİK YAPAY SİNİR AĞLARI

Bu bölüme kadar değişik yapay sinir ağlarının topolojileri, kullandıkları öğrenme stratejileri ve öğrenme kuralları ele alındı. Buraya kadar anlatılan ağların hepsinin tek başlarına problemleri çözmek üzere geliştirildikleri söylenmiştir. Yapay sinir ağlarının en iyi çözümü garanti etmediklerinde yine önemli bir özelliği olarak ortaya konuldu. Bu aslında önemli bir özelliktir. Yapay sinir ağlarının bağlantı ağırlıklarının başlangıç değerleri, eğitimde kullanılan örneklerin ağı sunuluş şekli, kullanılan öğrenme parametrelerinin belirlenen değerleri, öğrenmenin gerçekleştirildiği iterasyon sayısı vb. gibi bazı faktörler elde edilen sonuçların performansını yakından ilgilendirmektedir. Aynı ağ bu faktörlerin farklı değerlerine göre farklı sonuçlar üretebilmektedir. Örneğin sadece farklı başlangıç değerlerinden başlaması durumunda iki ağ eğitilse bir ağın tanıdığı bir örüntüyü diğer ağ tanıyamamaktadır. Ağların performansları eşit olsa bile birinin doğru sonuç ürettiği bir örnek için diğerinin farklı bir sonuç ürettiği görülebilmektedir. Bir problem için üretilen sonuçların deneme yanılma sonucu elde edilmesi en iyi topolojinin bulunmasını da zorlaştırmaktadır. Her türlü topolojiyi denemek mümkün değildir. Bu nedenlerden dolayı problemlere daha iyi sonuçlar üretebilmek için birden fazla ağın eğitilerek birlikte kullanılması ve bunların bir sinerjisini oluşturarak problemlere çözüm üretmek için birden fazla ağın birlikte kullanıldığı sistemler geliştirilmektedir.

Birden fazla ağın aynı probleme çözüm üretmek üzere geliştirildiği bu sistemlere **“birleşik ağlar”** denmektedir. Birleşik ağlar birden fazla uzmanın bir probleme çözüm üretmesine benzetilebilir. Bu uzmanların her birisi ilgili probleme farklı bir açıdan bakmakta ve hepsinin görüşleri bir araya getirildiğinde onların sinerjisi ile daha iyi ve doğru sonuç ortaya konulmaktadır. Birleşik ağlarda da birden fazla ağın her birisi olayın farklı bir yönünü öğrenebilmekte ve hepsinin kararları bir araya getirilerek ortak bir karar oluşturulmaktadır. Oluşturulan birleşik ağın performansı sistemi oluşturan ağların her birisinden tek tek daha yüksektir. Bu bölümde birleşik ağların yapısı, eğitilmesi ve ürettikleri çıktıların nasıl birleştirildiği konusu anlatılacaktır.

9.6. Özet

Yapay sinir ağlarının parametrelerinin değişik olması ve başlangıç değerlerinin değiştirilmesi neticesinde eğitilmeleri durumunda farklı sonuçlar ürettikleri görülmüştür. Bazı durumlarda tanıyamadıkları bir şekli diğer durumlarda öğrendikleri fark edilmiştir. Bunun neticesinde aynı problemi eğitime birden fazla ağın eğitilmesinin ve sonuçlarının bir araya getirilerek ortak bir kararın oluşturulmasının mümkün olabileceği görülmüştür. Birleşik ağlar denilen bu sistemler kendilerini oluşturan ağların her birinden performansı daha yüksek sonuçları üretilmesini sağlamaktadırlar. Bileşik ağlarda sistemin içinde bulunan ağlar kadar ortak karar vermeyi sağlayan mekanizmada önemlidir. Ağlar eğitilirken ve test edilirken diğerlerinden bağımsız olarak düşünülmektedir. Bütün ağlar eğitilip performansları onaylandıktan sonra bir araya getirilmektedir. Sistemde kullanılan ağların her hangi bir modelden seçilmesi gibi bir zorunluluk yoktur. Önemli olan birleşik sistemde bulunan ağların aynı problem üzerinde eğitilmiş olmaları ve çıktıların formatının ortak olmasıdır. Birleşik ağ içinde bulunan ağların topolojileri, kullandıkları toplama ve aktivasyon fonksiyonları, ara katman sayısı ve her ara katmanda bulunan eleman sayıları farklı olabilir. Girdi ve çıktı ünitelerinin sayılarının eşit olması gerekmektedir. Ağların birbirlerini ve karar vermelelerini etkilemeleri söz konusu değildir. Karar verme mekanizması kendisine gelen ağların bağımsız kararlarını “oy birliği” mantığında bir yaklaşım ile birleştirerek ağlara sunulan girdi hakkında bileşik sistemin kararını oluşturur. Geliştirilmiş birleşik sistemlerde sadece yapay sinir ağlarını kullanmak zorunlu değildir. Sisteme geleneksel yöntemleri de katmak olasıdır. Ağın öğrendiği olay hakkında geliştirilecek bir geleneksel ve sezgisel yöntem oluşturulabilirse o da sistemin bir parçası gibi değerlendirilebilir. Yapılan denemelerde yapay sinir ağlarının sezgisel yöntemler ile birlikte kullanılmasının sistemin performansını artırmada önemli bir katkısının olduğu görülmüştür. Ağların tek tek performanslarının %97 civarında olması durumunda geliştirilen bir bileşik sistemin performansının %99.5'lere çıkması bu ağların önemini ortaya koymaktadır.

YAPAY SİNİR AĞLARI DONANIMI

Günümüzde yapay sinir ağları uygulamalarının çoğu yazılım teknolojisi olarak görülmektedir. Belirli bir modelin yazılımı gerçekleştirilmekte ve seri bilgisayarlarda çalıştırılarak sorunların çözülmesi istenmektedir. Yapay sinir ağlarının paralellik gibi bazı özelliklerinin gösterilebilmesi için özel donanım teknolojisine ihtiyaç vardır. Yapay sinir donanımları ticari olarak genellikle şu alanlarda kendini göstermektedir:

- Optik karakter tanıma
- Ses tanıma
- Trafik izleme
- Veri madenciliği ve filtreleme

Yapay sinir ağları için özel donanım geliştirilmesinin bir çok yararı vardır. Bunlar arasında şunları saymak mümkündür.

- **Hız:** Bir çok uygulamada sistemin karar verme hızı çok önemlidir. Günümüzdeki en hızlı seri işlemciler bile özellikle çok sayıda girdi parametrenin gerektiği ve ağırlık boyutlarının çok büyük olması durumunda gerçek zamanlı kullanıma ve öğrenmeye uygun olmamaktadırlar. Sistemin gerçek zamanlı kullanılması için özel bir donanım ile sistemin hızının artırılması istenebilir. Örneğin birbirine paralel bağlanan işlemciler yardımıyla uygulamanın hızı artırılabilir.
- **Güvenirlilik:** Özel donanım sayesinde sistemin güvenirliliği artırılabilir. Özellikle donanım hatalarının kontrol altına alınması sağlanacağından sisteme olan inanç artacaktır.
- **Özel çalıştırma koşulları:** Donanımın probleme uygun bir şekilde tasarlanması özellikle sistemin boyutları, ağırlığı gibi konularda en uygun durumun seçilmesini sağlar.
- **Güvenlik:** Özel donanım ile sistemin güvenliği e koruması da daha rahat kontrol altına alınmaktadır.

10.5. Özet

Yapay sinir ağlarında yapılan çalışmalar ve bu kitapta anlatılan modeller genel olarak yazılım olarak geliştirilmekte ve seri makinelerde çalıştırılmaktadırlar. Bu ağların başarı bir şekilde uygulanmaları ve paralel çalışabilme özelliklerini göstermek için özel donanımlara ihtiyaç vardır. Bu konuda oldukça yoğun çalışmalar yapılmakta ve ticari sistemler oluşturulmaktadır. Bu donanımlar incelendiğinde genel olarak 3 tür donanım oluştuğu görülmektedir. Bunlar:

- Dijital yapay sinir ağı donanımları
- Analog yapay sinir ağı donanımları
- Karma donanımlar

Bunların her birisinin kendine göre avantaj ve dezavantajları vardır. Tasarımcılar, zaman, maliyet, ve problemin niteliğine bakarak kendileri için en uygun donanımı seçebilirler.

YAPAY SİNİR AĞLARI UYGULAMALARINA GENEL BİR BAKIŞ

Daha önceki bölümlerde yapay sinir ağları ve değişik modeller tanıtılmıştır. Değişik endüstriyel uygulamalar ayrıntılı olarak açıklanmıştır. Herhangi bir uygulama için ağ seçimi anlatılmıştır. Ağların avantaj ve dezavantajları tekrar gözden geçirilmiştir.

11.7. Özet

Bu bölümde yapay sinir ağlarının uygulamalarına genel bir bakış yapılmıştır. Genel olarak uygulamaların şu alanlarda görüldüğü belirtilmiştir.

- Endüstriyel uygulamalar
- Finansal uygulamalar
- Askeri ve savunma uygulamaları
- Sağlık uygulamaları

Bu alanlarda yapay sinir ağının bu alanlarda teşhis, sınıflandırma, tahmin, kontrol, veri ilişkilendirme, veri filtreleme, yorumlama gibi alanlarda kullanılmaktadır. Hangi problem için hangi ağın daha uygun olduğunu belirlemek için ağların özellikleri ile problemlerin özelliklerini karşılaştırmak gerekir. Her ağın çok iyi olduğu bazı özellikleri vardır. Örneğin ÇKA ağlarının tahmin problemlerinde çok iyi sonuçlar ürettiği bilinmektedir. Bu özelliklere göre problemler için uygun ağlar belirlenebilir.

Yapay sinir ağlarının bazı avantaj ve dezavantajları vardır. Bölüm içinde bunlar listelenmiştir. Yapay sinir ağlarının avantajlarından yararlanmak ve dezavantajlarını önleyecek şekilde sistemler oluşturmak için çalışmalar yapmak gerekmektedir.

Yapay sinir ağlarının geliştirilmesi diğer sistemlere göre oldukça kolaydır. Piyasada ticari olarak satılan simülörler vardır. Bu sistemlere sadece örnekler verilmekte ve ağın topolojisi belirlenmektedir. Öğrenme işimi simülör kendisi yapmaktadır. Bu simülörlerin test etme yetenekleri de vardır. Öğrenen ağın performansını da belirleyebilmektedir.

Yapay sinir ağları ile ilgili olarak bir çok kaynaktan ayrıntılı bilgiler almak mümkündür. Aşağıda yapay sinir ağlarının uygulamaları başta olmak üzere bu konuda okuyucuya yardımcı olacak kaynaklardan bazıları listelenmiştir.

Kaynakça

- [1] Hopfield, J. J. and Tank, D. W. 1985, "Neural computation of decisions in optimization problems," *Biological Cybernetics* , Vol. 52, pp. 141-152.
- [2] Sharda, R. 1994, "Neural networks for the MS/OR analyst: An application bibliography," *Interfaces*, Vol. 24, No. 2, pp. 116-130.
- [3] Wilson, R.L. and Sharda, R. 1992, "Neural networks," *OR/MS Today*, Vol. 19, No. 4, pp. 36-42.
- [4] Klimasauskas, C. C. 1989, *The 1989 Neuro-Computing Bibliography* , The MIT Press, Cambridge, MA.
- [5] Burke, L. L. and Ignizio, J. P. 1992, "Neural networks and operations research: An overview," *Computers and Operations Research*, Vol. 19, No. 3/4, pp. 179-189.
- [6] Widrow, B.; Rumelhart, D.E.; and Lehr, M.A. 1994, "Neural networks: Applications in industry, business, and science," *Communications of the ACM*, Vol. 37, No. 3, pp. 93-105.
- [7] Ripley, B.D. 1993, "Statistical Aspects of Neural Networks," Proceedings of Invited Lectures for SemStat, Sandbjerg, Denmark.
- [8] Kuan, C.M. and White, H. 1994, "Artificial neural networks: An econometric perspective," *Econometric Reviews*, Vol. 13, No. 1, pp. 1-91.
- [9] Wilson, R.L. and Sharda, R. 1994, "Bankruptcy prediction using neural networks," *Decision Support Systems*, Vol. 11, No. 5, pp. 545-557.
- [10] Fletcher, D. and Goss, E. 1993, "Forecasting with neural networks: An application using bankruptcy data," *Information and Management*, Vol. 24, No. 3, pp. 159-167.
- [11] Coats, P.K. and Fant, L.F. 1991, "A neural network approach to forecasting financial distress," *Journal of Business Forecasting*, Vol. 10, No. 4, pp. 9-12.
- [12] Coats, P.K. and Fant, L.F. 1993, "Recognizing financial distress patterns using a neural network tool," *Financial Management*, Vol.22,No.3, pp.142-155.
- [13] Collins, A. and Evans, A. 1994, "Aircraft noise and residential property values," *Journal of Transport Economics and Policy*, Vol.28, No. 2, pp. 175-197.
- [14] Altman, E.I.; Marco, G.; and Varetto, F. 1994, "Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the Italian experience)," *J. of Banking and Finance*, Vol. 18, No. 3, pp. 505-529.
- [15] Salchenberger, L. M.; Cinar, E. M.; and Lash, N. A. 1992, "Neural networks: A new tool for predicting thrift failures," *Decision Sciences*, Vol. 23, No. 4, (July/Aug.), pp. 899-916. Also reprinted in *Neural Networks in Finance and Investing* , ed. R. Trippi and E. Turban, Probus Publ. Co., Chicago, IL, 1993.
- [16] Tam, K. Y. and Kiang, M. Y. 1992, "Managerial applications of neural networks: The case of bank failure predictions," *Management Science*, Vol. 38, No. 7, (July), pp. 926-947. Also reprinted in *Neural Networks in Finance and Investing* , ed. R. Trippi and E. Turban, Probus Publishing Company, Chicago, IL, 1993.

- [17] Collins, J.M. and Clark, M.R. 1993, "An application of the theory of neural computation to the prediction of workplace behavior: An illustration and assessment of network analysis," *Personnel Psychology*, Vol. 46, No. 3, pp. 503-524.
- [18] Gorr, W.L.; Nagin, D.; and Szczypula, J. 1994, "Comparative study of artificial neural network and statistical models for predicting student grade point averages," *International Journal of Forecasting*, Vol. 10, No. 1, pp. 17-34.
- [19] Hardgrave, B.C.; Wilson, R.L.; and Walstrom, K.A. 1994, "Predicting graduate student success: A comparison of neural networks and traditional techniques," *Computers and Operations Research*, Vol. 21, No. 3, pp. 249-263.
- [20] Tsukuda, J. and Baba, S. 1994, "Predicting Japanese corporate bankruptcy in terms of financial data using neural network," *Computers and Industrial Engineering*, Vol. 27, No. 1-4, pp. 445-448.
- [21] Udo, G. 1993, "Neural network performance on the bankruptcy classification problem," *Computers and Industrial Engineering*, Vol.25, No.1-4, pp.377-380.
- [22] Piramuthu, S.; Shaw, M.J.; and Gentry, J.A. 1994, "A classification approach using multi-layered neural networks," *Decision Support Systems*, Vol. 11, No. 5, pp. 509-525.
- [23] Trippi, R.R. and DeSieno, D. 1992, "Trading equity index futures with a neural network," *Journal of Portfolio Management*, Vol. 19, No. 1, pp. 27-33.
- [24] Yoon, Y.; Swales, G.; and Margavio, T.M. 1993, "A comparison of discriminant analysis versus artificial neural networks," *Journal of the Operations Research Society*, Vol. 44, No. 1, pp. 51-60.
- [25] Kattan, M.W.; Adams, D.A.; and Parks, M.S. 1993, "A comparison of machine learning with human judgement," *Journal of Management Information Systems*, Vol. 9, No. 4, pp. 37-57.
- [26] Proctor, R.A. 1991, "An expert system to aid in staff selection: A neural network approach," *International Journal of Manpower*, Vol.12, No.8, pp.18-21.
- [27] Kryzanowski, L.; Galler, M.; and Wright, D.W. 1993, "Using artificial neural networks to pick stocks," *Financial Analysts Journal*, Vol.49, No.4, pp.21-27.
- [28] Collins, A. and Evans, A. 1994, "Aircraft noise and residential property values," *Journal of Transport Economics and Policy*, Vol.28, No.2, pp.175-197.
- [29] A Quang Do and Grudnitski, G. 1992, "A neural network approach to residential property appraisal," *Real Estate Appraiser*, Vol. 58, No. 3, pp. 38-45.
- [30] Balakrishnan, P. V.; Cooper, M.; Jacob, V. S.; and Lewis, P. A. 1996, "Comparative performance of the FSCL neural net and k-means algorithm for market segmentation," *European Journal of Operational Research*, In Press.
- [31] Curry, B. and Moutinho, L. 1993, "Neural networks in marketing: Modelling consumer responses to advertising stimuli," *European Journal of Marketing*, Vol. 27, No. 7, pp. 5-20.
- [32] Dasgupta, C.G.; Dispensa, G.S.; and Ghose, S. 1994, "Comparing the predictive performance of a neural network model with some traditional market response models," *International Journal of Forecasting*, Vol. 10, No. 2, pp. 235-244.

- [33] Proctor, R.A. 1992, "Marketing decision support systems: A role for neural networks," *Marketing Intelligence and Planning*, Vol. 10, No. 1, pp. 21-26.
- [34] McKim, R.A. 1993, "Neural network applications for project management: Three case studies," *Project Management Journal*, Vol. 24, No. 4, pp. 28-33.
- [35] Hansen, J. V.; McDonald, J.B.; and Stice, J.D. 1992, "Artificial intelligence and generalized qualitative-response models: An empirical test on two audit decision-making domains," *Decision Sciences*, Vol. 23, No. 3, pp. 708-723.
- [36] Hill, T.; Marquez, L.; O'Connor, M.; and Remus, W. 1994, "Artificial neural network models for forecasting and decision making," *International Journal of Forecasting*, Vol. 10, No. 1, pp. 5-15.
- [37] Wilson, R.L. 1994, "A neural network approach to decision alternative prioritization," *Decision Support Systems*, Vol. 11, No. 5, pp. 431-447.
- [38] Kuan, C.M. and Liu, T. 1992, "Forecasting exchange rates using feedforward and recurrent neural networks," Faculty Working Paper No. 92-0128, University of Illinois at Urbana-Champaign.
- [39] Bansal, A.; Kauffmann, R.J.; and Weitz, R.R. 1993, "Comparing the modeling performance of regression and neural networks as data quality varies: A business value approach," *Journal of Management Information Systems*, Vol. 10, No. 1, pp. 11-32.
- [40] Archer, N.P. and Wang, S. 1993, "Application of the backpropagation neural network algorithm with monotonicity constraints for two-group classification problems," *Decision Sciences*, Vol. 24, No. 1, pp. 60-75.
- [41] Curram, S.P. and Mingers, J. 1994, "Neural networks, decision tree induction and discriminant analysis: an empirical comparison," *Journal of the Operations Research Society*, Vol. 45, No. 4, pp. 440-450.
- [42] Liang, T.P.; Chandler, J.S.; Han, I.; and Roan, J. 1992, "An empirical investigation of some data effects on the classification accuracy of probit, ID3, and neural networks," *Contemporary Accounting Research*, Vol. 9, No. 1, pp. 306-328.
- [43] Patuwo, E.; Hu, M.H.; and Hung, M.S. 1993, "Two-group classification using neural networks," *Decision Sciences*, Vol. 24, No. 4, pp. 825-845.
- [44] Subramanian, V.; Hung, M.S., and Hu, M.Y. 1993, "An experimental evaluation of neural networks for classification," *Computers and Operations Research*, Vol. 20, No. 7, pp. 769-782.
- [45] Wang, S. 1995, "The unpredictability of standard back propagation neural networks in classification applications," *Management Science*, Vol. 41, No. 3, pp. 555-559.
- [46] Hurrion, R.D. 1993, "Representing and learning distributions with the aid of a neural network," *Journal of the Operational Research Society*, Vol. 44, No. 10, pp. 1013-1023.
- [47] Mangiameli, P.; Chen, S.K.; and West, D. 1996, "A comparison of SOM neural network and hierarchical clustering methods," *European Journal of Operational Research*, In Press.

- [48] Palocsay, S.W.; Stevens, S.P.; Brookshire, R.G.; Sacco, W.J.; Copes, W.S.; Buckman, R.F.; and Smith, J.S. 1996, "Using neural networks for trauma outcome evaluation," *European Journal of Operational Research*, In Press.
- [49] Wang, S. 1994, "Neural Networks for monotonic nonlinear models," *Computers and Operations Research*, Vol. 21, No. 2, pp. 143-154.
- [50] Wu, F.Y.; and Yen, K.K. 1992, "Applications of neural network in regression analysis," *Computers and Industrial Engineering*, Vol. 23, No. 1-4, pp. 93-95.
- [51] Caporaletti, L.E.; Dorsey, L.E.; Johnson, J.D.; and Powell, W.A. 1994, "A decision support system for in-sample simultaneous equation systems forecasting using artificial neural systems," *Decision Support Systems*, Vol. 11, No. 4, pp. 482-495.
- [52] Chu, C. and Widjaja, D. 1994, "Neural network system for forecasting method selection," *Decision Support Systems*, Vol. 12, No. 1, pp. 13-24.
- [53] Damodran, P.S.; Kolli, S.S.; and Alexander, S.M. 1993, "The investigation of new approaches to business data analysis," *Computers and Industrial Engineering*, Vol. 25, No. 1-4, pp. 545-548.
- [54] Lee, J.K. and Jhee, W.C. 1994, "A two-stage neural network approach for ARMA model identification with ESCAF," *Decision Support Systems*, Vol. 11, No. 4, pp. 461-479.
- [55] Lee, T.H.; White, H.; and Granger, C.W.J. 1993, "Testing for neglected nonlinearity in time series models," *Journal of Econometrics*, Vol. 56, pp. 269-290.
- [56] Anderson, J.A.; Pellionisz, A.; and Rosenfeld, E. (Eds) 1990, *Neurocomputing 2: Directions for research*, The MIT Press.
- [57] Tank, D. W. and Hopfield, J. J. 1986, "Simple 'neural' optimization networks: An A/D converter, signal decision circuit, and linear programming circuit," *IEEE Transaction on Circuits and Systems*, Vol. CAS33, No. 5 (May), pp. 533-541.
- [58] Dagli, C. H.; Kumara, S. R. T.; and Shin, Y. C. 1991, *Intelligent Engineering Systems Through Artificial Neural Networks*, ASME Press, Fairfield, NJ.
- [59] Ramanujam, J. and Sadayappan, P. 1988, "Optimization by neural networks," in *Proceedings of the IEEE International Conference on Neural Networks*, San Diego, CA, Vol. 2, pp. 325332.
- [60] Looi, C. 1992, "Neural network methods in combinatorial optimization," *Computers and Operations Research*, Vol. 19, No. 3/4, pp. 191-208.
- [61] Wang, J. and Chankong, V. 1991, "Neurally inspired stochastic algorithm for determining multi stage multi attribute sampling inspection plans," *Journal of Intelligent Manufacturing*, Vol. 2, No. 5 (October), pp. 327336.
- [62] de Carvalho, Luis A. V. and Barbosa, V. C. 1989, "Towards a stochastic neural model for combinatorial optimization," in *Proceedings of the IEEE International Joint Conf. on Neural Networks*, Washington D.C., Vol.2, pp.587.
- [63] Chakrapani, J. and Skorin-Kapov, J. 1992, "A connectionist approach to the quadratic assignment problem," *Computers and Operations Research*, Vol. 19, No. 3/4, pp. 287-295.

- [64] DeSilets, L.; Golden, B.; Kumar, R.; and Wang, Q. 1992, "A neural network model for cell suppression of tabular data," Working paper, College of Business and Management, University of Maryland, College Park, MD.
- [65] Glover, F. 1994, "Optimization by ghost image processes in neural networks," *Computers and Operations Research* , Vol. 21, No. 8, pp. 801-822.
- [66] Jagota, A. 1996, "An adaptive, multiple restarts neural network algorithm for graph coloring," *European Journal of Operational Research*, In Press.
- [67] Lee, B. W. and Sheu, B. J. 1990, "Combinatorial optimization using competitive Hopfield neural networks," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, Washington D.C., Vol. 2, pp. 627630.
- [68] Satake, T.; Morikawa, K.; and Nakamura, N. 1994, "Neural network approach for minimizing the makespan of the general job-shop," *International Journal of Production Economics*, Vol. 33, No. 1-3, pp. 67-74.
- [69] Wacholder, E. 1989, "A neural network based optimization algorithm for the static weapon target assignment problem," *ORSA Journal on Computing*, Vol. 1, No. 4 (Fall), pp. 232246.
- [70] Angeniol, B.; Croix Vaubois, G.; and Le Texier, J. 1988, "Self organizing feature maps and the travelling salesman problem," *Neural Networks*, Vol. 1, No. 4, pp. 289-293.
- [71] Bigus, J. P. and Goolsbey, K. 1990, "Integrating neural networks and knowledge based systems in a commercial environment," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, Washington D.C., Vol. 2, pp. 463466.
- [72] Burke, L. L. and Damany, P. 1992, "The guilty net for the traveling salesman problem," *Computers and Operations Research*, Vol.19, No.3/4, pp.255-266.
- [73] Dagli, C. H.; Ashouri, M. R.; Leininger, G.; and McMillin, B. 1990, "Composite stock cutting pattern classification through neocognition," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, Washington D.C., Vol. 2, pp. 587590.
- [74] Hegde, S. U.; Sweet, J. L.; and Levy, W. B. 1988, "Determination of parameters in a Hopfield/Tank computational network," in *Proceedings of the IEEE International Conference on Neural Networks*, San Diego, Vol. 2, pp. 291298.
- [75] Jeffries, C.; and Niznik, T. 1994, "Easing the conscience of the guilty net," *Computers and Operations Research* , Vol. 21, No. 9, pp. 961-968.
- [76] Xu, X. and Tsai, W. T. 1990, "An adaptive neural network algorithm for the traveling salesman problem," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, Washington D.C., Vol. 2, pp. 716719.
- [77] Zhang, L. and Thomopoulos, S. C. A. 1989, "Neural network implementation of shortest path algorithm for traffic routing in communication networks," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, Washington D.C., Vol. 2, pp. 591.
- [78] Cichocki, A.; Unbehauen, R.; Weinzeirl, K.; and Holzel, R. 1996, "A new neural network for solving linear programming models," *European Journal of Operational Research*, In Press.

- [79] Culioli, J. and Protopopescu, V. 1990, "Neural network models for linear programming," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, Washington D.C., Vol. 1, pp. 293296.
- [80] Wang, J. and Chankong, V. 1992, "Recurrent neural networks for linear programming: analysis and design principles," *Computers and Operations Research*, Vol. 19, No. 3/4, pp. 297-311.
- [81] Lin, Y; Austin, L.M.; and Burns, J.R. 1992, "An intelligent algorithm for Mixed-Integer programming models," *Computers and Operations Research*, Vol. 19, No. 6, pp. 461-468.
- [82] Kennedy, M. P. and Chua, L. O. 1988, "Neural networks for nonlinear programming," *IEEE Transactions on Circuits and Systems*, Vol. 35, No. 5 (May), pp. 554562.
- [83] Reklaitis, G. V.; Tsirukis, A. G.; and Tenorio, M. F. 1990, "Generalized Hopfield network and nonlinear optimization," in *Advances in Neural Information Processing Systems*, Vol. 2 (February), ed. D. Touretzky, Morgan Kaufmann Publishers, San Mateo, CA, pp. 355.
- [84] Nygard, K. E.; Juell, P.; and Kadaba, N. 1990, "Neural networks for selecting vehicle routing heuristics," *ORSA Journal on Computing*, Vol. 2, No. 4 (Fall), pp. 353364.
- [85] Potvin, J.-Y; Shen, Y; and Rousseau, J.-M. 1992, "Neural networks for automated vehicle dispatching," *Computers and Operations Research*, Vol. 19, No. 3,4, pp. 267-276.
- [86] Malakooti, B.; and Zhou, Y.Q. 1994, "Feedforward neural networks for solving discrete multiple criteria decision making problems," *Management Science*, Vol. 40, No. 11, pp. 1542-1561.
- [87] Wang, J. 1994, "Neural network approach to modeling fuzzy preference relations for multiple criteria decision making," *Computers and Operations Research*, Vol. 21, No. 9, pp. 991-1000.
- [88] Wang, J. and Malakooti, B. 1992, "A feedforward neural network for multiple criteria decision making," *Computers & Operations Research*, Vol. 19, No. 2, pp. 151-167.
- [89] Wang, S. and Archer, N.P. 1994, "A neural network technique in modeling multiple criteria multiple person decision making," *Computers and Operations Research*, Vol. 21, No. 2, pp. 127-142.
- [90] Sastri, T; English, J.; and Krishnamurthi, M. 1989, "Modeling a markovian decision process by neural network," *Computers and Industrial Engineering*, Vol. 17, No. 1-4, pp. 464-468.
- [91] Foo, Y. S. and Takefuji, Y. 1988, "Stochastic neural networks for jobshop scheduling: Parts 1 and 2," in *Proceedings of the IEEE International Conference on Neural Networks*, San Diego, CA, Vol. 2, pp. 275290.
- [92] Dagli, C.; and Sittisathanchai, S. 1993, "Genetic neuro-scheduler for job shop scheduling," *Computers and Industrial Engineering*, Vol. 25, No. 1-4, pp. 267-270.

- [93] Gulati, S.; Iyengar, S. S.; Toomarian, N.; Protopopescu, V.; and Barhen, J. 1987, "Nonlinear neural networks for deterministic scheduling," in *Proceedings of the IEEE International Conference on Neural Networks*, San Diego, CA, Vol. 4, pp. 745752.
- [94] Hellstrom, B. J. and Kanak, L. N. 1990, "Asymmetric meanfield neural networks for multiprocessor scheduling," Working paper #UMIACSTR9099, University of Maryland, College Park, MD.
- [95] Johnston, M.D.; and Adorf, H.-M. 1992, "Scheduling with neural networks - The case of the Hubble Space Telescope," *Computers and Operations Research*, Vol. 19, No. 3,4, pp. 209-240.
- [96] Kovacic, M. 1993, "Timetable construction with Markovian neural network," *European Journal of Operational Research*, Vol. 69, No. 1, pp. 92-96.
- [97] Mausser, H.E.; and Magazine, M.J. 1996, "Comparison of neural and heuristic methods for a timetabling problem," *European Journal of Operational Research*, In Press.
- [98] Poliac, M. O.; Lee, E. B.; Slagle, J. R.; and Wick, M. R. 1987, "A crew scheduling problem," in *Proceedings of the IEEE International Conference on Neural Networks*, San Diego, CA, Vol. 4, pp. 779786.
- [99] Rabelo, L. C.; Alptekin, S.; and Kiran, Ali S. 1990, "Synergy of artificial neural networks and knowledgebased expert systems for intelligent FMS scheduling," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, San Diego, CA, Vol. 1, pp. 359366.
- [100] Sabuncuoglu, I; and Gurgun, B. 1996, "A neural network model for scheduling problems," *European Journal of Operational Research*, In Press.
- [101] Tanaka, T.; Canfield, J.R.; Oyanagi, S.; and Genchi, H. 1989, "Optimal task assignment using neural network," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, Washington D.C., Vol. 2, pp. 591.
- [102] Vaithyanathan, S. and Ignizio, J. P. 1992, "A stochastic neural network for resource constrained scheduling," *Computers and Operations Research*, Vol. 19, No. 3/4, pp. 241-254.
- [103] Yu, T. L. 1990, "Time table scheduling using neural network algorithms," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, San Diego, CA, Vol. 1, pp. 279284.
- [104] Zhou, D. N.; Cherkassky, V.; Baldwin, T. R.; and Hong, D. W. 1990, "Scaling neural network for jobshop scheduling," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, San Diego, CA, Vol. 3, pp. 889894.
- [105] Burke, L. L. and Rangwala, S. 1991, "Tool condition monitoring in metal cutting: A neural network approach," *Journal of Intelligent Manufacturing*, Vol. 2, No. 5 (October), pp. 269280.
- [106] Chakraborty, K.; and Roy, U. 1993, "Connectionist models for part-family classifications," *Computers and Industrial Engineering*, Vol. 24, No. 2, pp. 189-198.
- [107] Dagli, C. and Lammers, S. 1989, "Possible applications of neural networks in manufacturing," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, Washington D.C., Vol. 2, pp. 605.

- [108] Kao, Y. and Moon, Y. B. 1991, "A unified group technology implementation using the backpropagation learning rule of neural networks," *Computers and Industrial Engineering*, Vol. 20, No. 4, pp. 425-437.
- [109] Kaparthi, S. and Suresh, N.C. 1994, "Performance of selected part-machine grouping techniques for data sets of wide ranging sizes and imperfection," *Decision Sciences*, Vol. 25, No. 4, pp. 515-539.
- [110] Kaparthi, S.; Suresh, N.C.; and Cervaney, R.P. 1993, "An improved neural network leader algorithm for part-machine grouping in group technology," *European Journal of Operational Research*, Vol. 69, No. 3, pp. 342-356.
- [111] Ko, T.J.; Cho, D.W.; and Jung, M.Y. 1995, "On-line monitoring of tool breakage in face milling using a self-organized neural network," *Journal of Manufacturing Systems*, Vol. 14, No. 2, pp. 80-90.
- [112] Kumara, S. R. T.; and Kamarthi, S. V. 1991, "Function-to-structure transformation in conceptual design: An associative memory paradigm," *Journal of Intelligent Manufacturing*, Vol. 2, pp. 281-292.
- [113] Lee, S. and Chen, H. 1991, "Design optimization with back propagation neural networks," *Journal of Intelligent Manufacturing*, Vol. 2, No. 5 (October), pp. 293-304.
- [114] Lee, S. and Park, J. 1991, "Neural computation for collision free path planning," *Journal of Intelligent Manufacturing*, Vol.2, No.5 (Oct.), pp. 315-326.
- [115] Liao, T.W.; and Lee, K. S. 1994, "Integration of a feature-based CAD system and an ART1 neural model for GT coding and part family forming," *Computers and Industrial Engineering*, Vol. 26, No. 1, pp. 93-104.
- [116] Madey, G. R.; Weinroth, J.; and Shah, V. 1992, "Integration of neurocomputing and system simulation for modeling continuous improvement systems in manufacturing," *Journal of Intelligent Manufacturing*, Vol. 3, pp. 193-204.
- [117] Malave, C. O. and Ramachandran, S. 1991, "Neural network based design of cellular manufacturing systems," *Journal of Intelligent Manufacturing*, Vol. 2, No. 5 (October), pp. 305-314.
- [118] Romano, R.; Maimon, O.; and Furst, M. 1989, "Neural net implementation for assigning a product to a production line," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, Washington D.C., Vol. 2, pp. 577.
- [119] Sieger, D.B.; and Badiru, A.B. 1993, "An artificial neural network case study: Prediction versus classification in a manufacturing application," *Computers and Industrial Engineering*, Vol. 25, No. 1-4, pp. 381-384.
- [120] Smith, K.; Palaniswami, M.; and Krishnamoorthy, M. 1996, "Traditional heuristic versus hopfield neural network approaches to a car sequencing problem," *European Journal of Operational Research*, In Press.
- [121] Sunil, E. V. T.; Shin, Y. C.; and Kumara, S. R. T. 1990, "Machining condition monitoring via neural networks," in *Monitoring and Control of Manufacturing Processes*, eds. S. Y. Liang and T. Tso, ASME Press, Fairfield, NJ, pp. 85-95.
- [122] Wang, J. 1994, "A neural network approach to multiple objective cutting parameter optimization based on fuzzy preference information," *Computers and Industrial Engineering*, Vol. 25, No. 1-4, pp. 389-392.

- [123] Wang, Q.; Sun, X.; Golden B.L.; and DeSilets, L. 1993, "A neural network model for the wire bonding proces," *Computers and Operations Research*, Vol. 20, No. 8, pp. 879-888.
- [124] Zhou, Y. and Malakooti, B. 1991, "Inprocess regressions and adaptive neural networks for monitoring and supervising machining operations," Technical report #91182, Case Western Reserve University, Cleveland, OH.
- [125] Benjamin, C.O.; Chi, S.-C.; Gaber, T.; and Riordan, C.A. 1995, "Comparing BP and ART II neural network classifiers for facility location," *Computers and Industrial Engineering* , Vol. 28, No. 1, pp. 43-50.
- [126] Gaber, M.T.; and Benjamin, C.O. 1992, "Classifying U.S. manufacturing plant locations using an artificial neural network," *Computers and Industrial Engineering*, Vol. 23, No. 1-4, pp. 101-104.
- [127] Vaithyanathan, S.; Burke, L.I.; and Magent, M.A. 1996, "Massively parallel analog Tabu search using neural networks applied to simple plant location problems," *European Journal of Operational Research*, In Press.
- [128] Alpaydin, E.; Altinel, K.I.; and Aras, N. 1996, "Parametric distance functions vs. nonparametric neural networks for estimating road travel distances," *European Journal of Operational Research*, In Press.
- [129] Yuan, Y; and Wang, L. 1996, "A neural network approach to solve the stable matching problem," *European Journal of Operational Research*, In Press.
- [130] Steiger, D.M.; and Sharda, R. 1996, "Analyzing mathematical models with inductive learning networks," *European Journal of Operational Research*, In Press.
- [131] Cheng, C.-S. 1995, "A multi-layer neural network model for detecting changes in the process mean," *Computers and Industrial Engineering*, Vol. 28, No. 1, pp. 51-61.
- [132] Hwarng, H. B.; and Hubblee, N. F. 1993, "X control chart pattern identification through efficient off-line neural network training," *IIE Transactions*, Vol. 25, No. 3, pp. 27-40.
- [133] Pugh, G.A. 1989, "Synthetic neural networks for process control," *Computers and Industrial Engineering*, Vol. 17, No. 1-4, pp. 24-26.
- [134] Anandalingam, G.; Mathieu, R.; Pittard, C. L.; and Sinha, N. 1989, "Artificial intelligence based approaches for solving hierarchical optimization problems," in *Impact of Recent Computer Advances on Operations Research*, eds. R. Sharda et al, North Holland, New York, pp. 289301.
- [135] Denton, J.W.; and Hung, M.S. 1996, "A comparison of non linear optimization methods for supervised learning in multilayer feedforward neural networks," *European Journal of Operational Research*, In Press.
- [136] Denton, J. W. and Hung, M. S. 1992, "Second order training methods for supervised learning in neural networks," paper presented at the TIMS/ORSA Joint National Meeting, Orlando, FL.
- [137] Hung, M.S.; and Denton, J.W. 1993, "Training neural networks with the GRG2 nonlinear optimizer," *European Journal of Operational Research*, Vol. 69, No. 1, pp. 83-91.

- [138] Shawe-Taylor, J. S. and Cohen, D. A. 1990, "Linear programming algorithm for neural networks," *Neural Networks* , Vol. 3, No. 5, pp. 575-582.
- [139] Bennet, K. P. and Mangasarian, O. L. 1992a, "Robust linear programming discrimination of two linearly inseparable sets," *Optimization Methods and Software*, Vol. 1, pp. 23-34.
- [140] Bennet, K. P. and Mangasarian, O. L. 1992b, "Neural network training via linear programming," in *Advances in Optimization and Parallel Computing*, ed. P. M. Pardalos, North Holland, Amsterdam, pp. 56-67.
- [141] Roy, A. and Mukhopadhyay, S. 1991, "Pattern classification using linear programming," *ORSA Journal on Computing*, Vol.3, No.1 (Winter), pp. 6680.
- [142] de Werra, D. and Hertz, A. 1989, "Tabu search techniques: A tutorial and an application to neural networks," *OR Spektrum*, Vol.11 No.3, pp.131-141.
- [143] Jones, K. L.; Lustig, I. J.; and Kornhauser, A. L. 1990, "Optimization techniques applied to neural networks: Line search implementation for backpropagation," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, San Diego, CA, Vol. 3, pp. 933-940.
- [144] Bennet, K. P. 1992, "Decision tree construction via linear programming," in *Proceedings of the 4th Midwest Artificial Intelligence and Cognitive Science Conference*, pp. 97-101.
- [145] Baek, W.; and Ignizio, J.P. 1993, "Pattern classification via linear programming," *Computers and Industrial Engineering* , Vol. 25, No. 1-4, pp. 393-396.

Dizin

ADALINE 38,39,59,68-73
adaptif doğrusal eleman 68
Ağ seçimi 207
ağın büyütülmesi/budanması 104/105
eğitilmesi 55,82
ezberlemesi 90,91
öğrenmesi/test edilmesi 55
performansı 90
topolojisi 81
aktivasyon fonksiyonu 48,50,51
algılama/algılayıcılar 20/38
analog yapay sinir ağları 200
ara katman 52,53,76,77,112
ART 25,39,41, 56,137-143,161,207
ağlarında etiketlendirme 153
ağlarının yapısı 141
ART1 140,143,145-147,155
ağı uygunluk testi 146,157,159,160
ART2 140,143, 147-153,162
ağının çalışma prensibi 149,150
ağının öğrenme kuralı 150-153
ağının yapısı 148,149
ART3 140,162
ARTMAP 140,162
Atansiyonel alt sistem 149
Axon 47
Bağlantılar 52
Bağlantılı ağlar 30
BAM 207
Benzerlik katsayısı 145,146
Bilgi tabanı 15
Bilginin elde edilmesi 14, 15
Birleşik ağlar 183, 187-195
ağların eğitilmesi/test edilmesi 189
ağların yapısı 188
Biyolojik Sinir ağları 45
Boltzman makinesi 41, 56
Bulanık önermeler mantığı 18, 33
Büyüyen ağlar 105
Cezalandırma mekanizmalı LVQ 123,133, 134
Cognitron ağı 170,176-180,185
ağında bağlantılar 177
ağında yarışma alanları 177
ağının eğitilmesi 179,180
Counterpropagation ağı 170,173,185,207
Çaprazlama 17
Çevrim dışı öğrenme (bkz. off-line öğrenme)

Çevrim içi öğrenme (bkz. on-line öğrenme)
Çıkarım mekanizması 15
Çıktı fonksiyonu (bkz. aktivasyon fonk.) 60
Çıktı vektörü/katmanı 24,54/53,76,77,112
Çıktıların ölçeklendirilmesi 102,1003
ÇKA 75-116,135,172,183,184, 188, 193,194,207
ağının çalışma prosedürü 81
ağının eğitilmesi 110,112
ağının oluşturulması 109
ağının öğrenme setinin oluşturulması 108
Çok boyutlu hata uzayı 83
Çok katmanlı algılayıcı 25,41, 50, 56, 68, 75-113
Çokgen komşuluk alanı 183
Dağıtık bellek 33
Davranışların açıklanması 35
Delta öğrenme kuralı 26,27,28,76
Dendrite 47
Dereceli bozulma 33
Destekleyici öğrenme (bkz. öğrenme stra.) 25,115
Dijital yapay sinir ağı 198
Donanım performansı 202
Dörtgen komşuluk alanı 183
Eğitim seti 56,92
Eğitimi durdurma kriterleri 103
Eksik bilgi ile çalışabilme 32,35
Elman ağı 56, 166-169
Elman ağının öğrenmesi 168
Eşik değeri 59, 62, 76,79,80,86
Evrimsel programlama 23
Farklı çağrışım 22
Fonksiyonel birliktelik 194
Fuzzy ART 140,162
Gen 17
Genelleme 29
Genelleştirilmiş delta kuralı 77
Genetik Algoritmalar 17,23
Geri doğru zincirleme 16
Geri dönüşümlü ağlar 165-173
Girdi katmanı 52,53,76,77,112
Girdi vektörü 24,54
Girdinin ölçeklendirilmesi 102
Global çözüm 83
kazanan 124,125
GRNN 40,41

Grosberg Katmanı	174	Optimizasyon	29,36
öğrenme kuralı	39	Optimum öğrenme	35
Grup teknolojisi	154,155	Ortogonal dizi	108
Hafıza	137	Oryantasyon	142,143,149
Hata toleransı	33	Oto çağrışım	22
Hata uzayı	82	Öğrenen makinalar	38
Hebb öğrenme kuralı (Hebbian ögr.)	26,37	Öğrenme eğrisi	84
Hopfield ağı	26, 28 56, 170-173,185,207	katsayısı	24,63,99,110
İçerik elemanları	166-169	kuralları	26,55
İleri doğru zincirleme	16	paradigmaları	23
İlişkilendirme (bkz. veri ilişkilendirme)	29,36	performansı	132
İstatistiki kalite kontrolü	126	stratejileri	24
Kara kutu yaklaşımı	54	Öğrenme türleri	22
Karar verme modülü	188,190-192	Öğretmenli/öğretmensiz öğrenme	25
Karma ağlar	183	Örneklerden öğrenme	23
Karma donanım tasarımları	201	Örneklerin seçilmesi	91
Kategori gösterim alanı (vektörü)	141,147	Özellik gösterim alanı	141
Kazanan elemanın seçilmesi	146,152,157,159,160	Periyodik şeklin üretilmesi	130
Kazanç değeri (K1 ve K2)	142-145,156	Perseptron (bkz. Tek katmanlı algı.)	59-69,75
Kendi kendini organize etme	32	PNN	40,41, 56, 207
Kesikli Hopfield ağı	171-173	Proses elemanı	48,49,53
Kısa dönemli hafıza	137,138,140-142	Radyal temelli fonksiyon (RBF)	41, 56, 199
Kısmi geri dönüşümlü ağlar	165	Rasgele sunum	100
Kohonen katmanı	174-176	Rassal Ağlar	37
Kohonen öğrenme kuralı	27,28,118	Referans vektörü	117,120
Kromozom	17	Sınıf ayracı	60
LVQ	25,56, 115-135,139,184,188,193, 194, 207	Sınıfın etiketlenmesi	153
ağının çıktı katmanı	116	Sınıflandırma	29, 32, 36, 105, 113, 115, 204, 207
Kohonen katmanı	116,120,131, 134	Sıralı sunum	100
ağının girdi katmanı	116	Sigmoid fonksiyonu	50,51,78,80,102,167,168
ağının çalışma prosedürü	117	SOM	39,41, 56, 170,180-183,185
ağının eğitilmesi	120	ağının eğitilmesi	182
ağının oluşturulması	130	ağının gösterimi	181
ağının özellikleri	115	Soma	47
ağının yapısı	116	Standart LVQ	132,134
LVQ2	122,123,132,134,135	Sürekli Hopfield ağı	171,173
LVQ-X	124,133,134,135	Synaps	47
MADALINE	38,59, 73,74	Taguchi metodu	107,111,112
Makine öğrenmesi	17,21	Tam geri dönüşümlü ağlar	165
Men edici proses elemanı	177-179	Tek katmanlı algılayıcı	39,59-69
Momentum katasyısı	99,110	Test performansı	132
Mutasyon	17	Test seti	56,92
Mutasyon oranı	17	Toplama fonksiyonu	48,49,50
Mümküniyet değeri	19	Trend şeklinin üretilmesi	129
NEOCOGNITRON	39,176,180	Uygunluk fonksiyonu	17
Normal şeklin üretilmesi	129	Uzman sistemler	15,16
Normalizasyon	138	Uzun dönemli hafıza	137,140
Nuromofik sistemler	30	Üyelik fonksiyonu	19
Off-line öğrenme	26,139	Veri filtreleme	204
On-line öğrenme	26,32,148,161	Veri ilişkilendirme	204,207
		XOR problemi	38,40,42,75,85-90

Yapay Sinir Ağları

XPC	127,128	Yeniden yerleştirme modülü (YYM)	142-144
Yapay sinir ağı tanımı	30	Yerel kazanan	124,125
Yapay sinir ağı uygulamaları	36,203-209	Yukarı kayma şeklin üretilmesi	130
Yapay sinir ağının eğitilmesi	55	Zeki etmen	20,21
Yapay sinir ağları bilgi kaynakları	210	Zeki kalite kontrol sistemi	127,131
Yapay sinir hücresi	48,52		
Yapay zeka	13, 14		