

T.C.
MUĞLA SITKI KOÇMAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İSTATİSTİK ANABİLİM DALI

YAPAY SİNİR AĞLARINDA EN İYİ MİMARİ
SEÇİMİ İÇİN KULLANILAN KRİTERLERİN
İNCELENMESİ

YÜKSEK LİSANS

ÇAĞATAY BAL

MART 2018

MUĞLA

T.C.
MUĞLA SITKI KOÇMAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İSTATİSTİK ANABİLİM DALI

YAPAY SİNİR AĞLARINDA EN İYİ MİMARİ
SEÇİMİ İÇİN KULLANILAN KRİTERLERİN
İNCELENMESİ

YÜKSEK LİSANS

ÇAĞATAY BAL

MART 2018

MUĞLA

MUGLA SITKI KOÇMAN ÜNİVERSİTESİ

Fen Bilimleri Enstitüsü

TEZ ONAYI

ÇAĞATAY BAL tarafından hazırlanan **YAPAY SİNİR AĞLARINDA EN İYİ MİMARİ SEÇİMİ İÇİN KULLANILAN KRİTERLERİN İNCELENMESİ** başlıklı tezinin, 16/03/2018 tarihinde aşağıdaki jüri tarafından İstatistik Anabilim Dalı'nda yüksek lisans derecesi için gerekli şartları sağladığı oybirliği ile kabul edilmiştir.

TEZ SINAV JURİSİ

Doç. Dr. Çağdaş Hakan ALADAĞ* (Jüri Başkanı)

İstatistik Anabilim Dalı,
Hacettepe Üniversitesi, Ankara

İmza:

Doç. Dr. Serdar DEMİR (Danışman)

İstatistik Anabilim Dalı,
Muğla Sıtkı Koçman Üniversitesi, Muğla

İmza:

Yrd. Doç. Dr. Nevin GÜLER DİNCER (Üye)

İstatistik Anabilim Dalı, Muğla Sıtkı Koçman Üniversitesi, Muğla

İmza:

ANA BİLİM DALI BAŞKANLIĞI ONAYI

Doç. Dr. Dursun AYDIN

İstatistik Ana Bilim Dalı Başkanı,
Muğla Sıtkı Koçman Üniversitesi, Muğla

İmza:

Doç. Dr. Serdar DEMİR

Danışman, İstatistik Anabilim Dalı,
Muğla Sıtkı Koçman Üniversitesi, Muğla

İmza:

Savunma Tarihi: 16/03/2018

Tez alıřmalarım sırasında elde ettiėim ve sunduėum tm sonu, dokman, bilgi ve belgelerin tarafımdan bizzat ve bu tez alıřması kapsamında elde edildiėini; akademik ve bilimsel etik kurallarına uygun olduėunu beyan ederim. Ayrıca, akademik ve bilimsel etik kuralları gereėi bu tez alıřması sırasında elde edilmemiř bařkalarına ait tm orijinal bilgi ve sonulara atıf yapıldıėını da beyan ederim.

aėatay BAL

16/03/2018

ÖZET
YAPAY SINIR AĞLARINDA EN İYİ MİMARİ SEÇİMİ İÇİN
KULLANILAN KRİTERLERİN İNCELENMESİ

Çağatay BAL

Yüksek Lisans Tezi

Fen Bilimleri Enstitüsü

İstatistik Anabilim Dalı

Danışman: Doç. Dr. Serdar DEMİR

Mart 2018, 122 sayfa

Yapay sinir ağları zaman serisi analizi için kullanıldığında mimari seçimi işlemi, en iyi öngörüler üretecek yapay sinir ağları modelinin belirlenmesidir. Modelin ürettiği öngörü değerleriyle sinir ağının hedef değerleri olan gerçek gözlemler arasındaki hatayı minimum yapan mimari, en iyi öngörüyle dolayısıyla en uygun modeli temsil etmektedir. Bu işlemi gerçekleştirebilmek için literatürde birçok kriter kullanılmaktadır. Bunların yanı sıra, bu kriterlerin bir araya getirilmesiyle oluşturulan ve ağırlıklı kriterler olarak adlandırılan çeşitli kriterler de mevcuttur. Bu tez çalışmasında, literatürdeki mevcut kriterler incelenmekte, performansları karşılaştırılmakta ve gerçek verilere uygulamaları gerçekleştirilmektedir. Performans karşılaştırmaları için 3 farklı döviz paritesini içeren zaman serisiyle birlikte farklı özelliklere sahip 4 zaman serisi simüle edilmiş ayrıca literatürde bilinen 3 farklı gerçek hayat verisi kullanılmıştır. Yapay sinir ağları modellemesinin en önemli adımlardan biri olan en iyi mimarinin seçilmesine ilişkin literatürdeki yaklaşımların böyle bir çalışmada bir arada karşılaştırmalı olarak incelenmesinin, farklı bilim alanlarında çalışan araştırmacıların ilgisini çekeceği ve modelleme uygulamalarında yararlı bir kaynak olacağı düşünülmektedir.

Anahtar Kelimeler: Yapay Sinir Ağları, Performans Kriterleri, En İyi Mimari, Öngörü, Zaman Serisi

ABSTRACT
INVESTIGATION OF CRITERIA FOR THE BEST ARCHITECTURE
SELECTION OF ARTIFICIAL NEURAL NETWORKS

Çağatay BAL

Master of Science (M.Sc.)

Institute of Sciences

Department of Statistics

Supervisor: Assoc. Prof. Dr. Serdar DEMİR

March 2018, 122 pages

The architecture selection in artificial neural networks means that the neural network model to be used for prediction in the time series is the model that will give the most appropriate results. The architecture that minimizes the error between the target values of the neural network which are the real observations and the predicted values generated by the model represents the best forecasts namely the most appropriate model. There are many criteria that are used in the literature to accomplish this process. In addition to these, there are various criteria which are created by combining these criteria and called as weighted criteria. In this thesis study, the existing criteria in the literature are examined, their performances are compared by applying to both simulated and real world data sets. For performance comparisons, 3 different exchange rates time series, 4 simulated time series with different features and 3 well known real world data sets are obtained. As a comparative study on the selection of the best architecture which is one of the most important steps in the modelling of artificial neural networks. It is hoped that it will be a useful and attracting resource for researchers working on modelling data in different fields of science.

Keywords: Artificial Neural Networks, Performance Criteria, Best Architecture, Forecast, Time Series



Sevgili Eşime

ÖNSÖZ

Bu tezin yazarı Arş. Gör. Çağatay BAL olarak çalışmalarım sırasında göstermiş olduğu kolaylıklar ve bilimsel bir çalışmanın, düşünmenin temellerini öğrettiği danışmanım Doç. Dr. Serdar DEMİR'e ve sayın hocam Yrd. Doç. Dr. Nevin GÜLER DİNCER'e teşekkürlerimi bir borç bilirim.

Tezin ana hatlarının belirlenmesinde değerli katkılarını esirgemeyen sayın Doç. Dr. Çağdaş Hakan ALADAĞ hocama da şükranlarımı sunarım.

Ayrıca çalışmamın tüm aşamalarında sabırla beni destekleyen sevgili eşim Aslı Bal'a, minettar olduğumu belirtmek isterim.

Bu tez çalışması, 16/130 numaralı Bilimsel Araştırma Projesiyle desteklenmiştir.

İÇİNDEKİLER

ÖNSÖZ	vii
İÇİNDEKİLER	viii
ÇİZELGELER DİZİNİ	xi
ŞEKİLLER DİZİNİ	xiii
SEMBOLLER VE KISALTMALAR DİZİNİ	xv
1. SINIR AĞLARINA GİRİŞ	1
1.1. Esnek Hesaplama Yöntemleri ve Yapay Zekâ	1
1.1.1. Esnek hesaplama yöntemlerinin karakteristikleri	6
1.2. Sinir Ağları	7
1.2.1. Biyolojik sinir ağları	7
1.2.2. Yapay sinir ağları	9
1.3. Sinir Ağlarının Kullanıldığı Alanlar	12
1.3.1. Tahmin ve öngörü	12
1.3.1.1. Zaman serileri analizinde tahmin yöntemleri	13
1.3.1.2. Geleneksel zaman serileri tahmini	13
1.3.1.3. YSA ile zaman serileri tahmini	13
1.3.2. Sınıflama(Classification)	14
1.3.3. Kümeleme(Clustering)	14
1.3.4. Sinyal işleme	14
1.3.5. Görüntü tanımlama	15
1.3.6. Ses işleme	15
1.3.7. Ses tanımlama	16
1.3.8. Optimizasyon	16
1.3.9. Sağlık	16
1.3.10. Kontrol	16
1.3.11. İşletme	17
1.4. Tarihçe	17

1.5. Genel Özellikleri -----	20
1.5.1. Öğrenme-----	20
1.5.2. Doğrusal olmama -----	20
1.5.3. Uyarlanabilirlik-----	20
1.5.4. Hata toleransı -----	21
1.5.5. Genelleme-----	21
1.5.6. Avantaj ve dezavantajları -----	21
2. YAPAY SİNİR AĞLARI -----	22
2.1. Yapay Sinir Ağları Bileşenleri -----	22
2.1.1. Mimari yapı-----	22
2.1.2. Öğrenme algoritması -----	22
2.1.3. Aktivasyon fonksiyonu-----	23
2.2. Sinyal Akışına Göre Yapay Sinir Ağları-----	24
2.2.1. İleri beslemeli ağlar-----	24
2.2.2. Geri beslemeli ağlar -----	25
2.3. Öğrenme Yöntemlerine Göre Yapay Sinir Ağları-----	26
2.3.1. Denetimli öğrenme -----	26
2.3.2. Denetimsiz öğrenme-----	26
2.3.3. Destekleyici öğrenme -----	26
2.4. Öğrenme Kuralına Göre Yapay Sinir Ağları -----	27
2.4.1. Çevrimiçi öğrenme -----	27
2.4.2. Çevrimdışı öğrenme -----	27
2.4.3. Gerçek zamanlı yinelemeli öğrenme -----	27
2.4.4. Melez öğrenme kuralı : dik iniş ve en küçük kareler -----	28
2.5. Uyarlamalı Sinir Ağları -----	29
2.5.1. Giriş-----	29
2.5.2. Uyarlamalı ağ mimarisi -----	30
2.6. Tek Tabakalı Algılayıcılar -----	32
2.6.1. Giriş-----	32
2.6.2. Tek katmanlı doğrusal algılayıcı (perceptron)-----	33
2.6.2.1. Mimari yapı ve öğrenme kuralı-----	33
2.6.2.2. Tek katmanlı doğrusal algılayıcı algoritması -----	34
2.6.3. Uyarlamalı doğrusal ağlar -----	36
2.6.3.1. Mimari yapı ve öğrenme kuralı-----	36

2.6.3.2. Uyarlamalı doğrusal ağlar algoritması -----	37
2.6.4. XOR problemi -----	38
2.7. Çok Tabakalı Algılayıcılar ve Geri Yayılım Algoritması -----	41
2.7.1. İleri beslemeli ağlar için geri yayılım ve sıralı türev -----	41
2.7.2. Geri beslemeli ağlar için genişletilmiş geri yayılım -----	45
2.7.3. Çok tabakalı algılayıcılarda geri yayılım -----	45
2.7.3.1. Geri yayılım algoritması -----	46
2.7.3.2. Eğitimin hızlandırılması için yöntemler -----	48
2.7.3.3. Çok tabakalı algılayıcıların tahmin gücü -----	49
2.8. Model Seçimi Yöntemleri -----	49
2.8.1. Örneklem içi model seçimi -----	50
2.8.2. Örneklem dışı model seçimi -----	50
3. PERFORMANS ÖLÇÜTLERİ -----	52
3.1. Giriş -----	52
3.2. Mutlak Hatalara Dayalı Ölçütler -----	52
3.3. Orantılı Hatalara Dayalı Ölçütler -----	53
3.4. Simetrik Hatalara Dayalı Ölçütler -----	54
3.5. Göreceli Hatalara Dayalı Ölçütler -----	54
3.6. Ölçekli Hatalara Dayalı Ölçütler -----	55
3.7. Ağırlıklara Dayalı Ölçütler -----	55
3.8. Diğer Ölçütler -----	57
4. GERÇEK VE YAPAY VERİLER İLE PERFORMANS ÖLÇÜTLERİNİN KARŞILAŞTIRILMASI -----	60
4.1. Modelleme -----	65
4.1.1. Verinin tasarımı ve ön işleme -----	66
4.1.2. Yapay sinir ağları tasarımı ve kodlama -----	68
4.2. Uygulama Sonuçları -----	69
4.2.1 Döviz kurlarına ilişkin sonuçlar -----	69
4.2.2 Simüle edilen zaman serilerine ilişkin sonuçlar -----	84
4.2.3 Gerçek zaman serilerine ilişkin sonuçlar -----	100
5. SONUÇ VE TARTIŞMA -----	113
KAYNAKLAR -----	116
ÖZGEÇMİŞ -----	122

ÇİZELGELER DİZİNİ

Çizelge 2.1. XOR işlemi.	39
Çizelge 4.1. Yapay Sinir Ağları' nın çalışma prensibi	67
Çizelge 4.2. AVRO döviz kuruna ilişkin sonuçlar.....	70
Çizelge 4.3. AVRO döviz kuruna ilişkin performans ölçütlerinin hata değerleri sonuçları	71
Çizelge 4.4. İNGİLİZ STERLİNİ döviz kuruna ilişkin sonuçlar	75
Çizelge 4.5. İNGİLİZ STERLİNİ döviz kuruna ilişkin performans ölçütlerinin hata değerleri sonuçları.....	76
Çizelge 4.6. JAPON YENİ döviz kuruna ilişkin sonuçlar	80
Çizelge 4.7. JAPON YENİ döviz kuruna ilişkin performans ölçütlerinin hata değerleri sonuçları	81
Çizelge 4.8. DOĞRUSAL OLMAYAN OTOREGRESİF veri setine ilişkin sonuçlar	84
Çizelge 4.9. DOĞRUSAL OLMAYAN OTOREGRESİF simülasyon verisine ilişkin performans ölçütlerinin hata değerleri sonuçları.....	85
Çizelge 4.10. MEVSİMSEL OTOREGRESİF veri setine ilişkin sonuçlar	88
Çizelge 4.11. MEVSİMSEL OTOREGRESİF simülasyon verisine ilişkin performans ölçütlerinin hata değerleri sonuçları	89
Çizelge 4.12. SİNÜS veri setine ilişkin sonuçlar	92
Çizelge 4.13. SİNÜS simülasyon verisine ilişkin performans ölçütlerinin hata değerleri sonuçları.....	93
Çizelge 4.14. ÜSTEL veri setine ilişkin sonuçlar	96
Çizelge 4.15. ÜSTEL simülasyon verisine ilişkin performans ölçütlerinin hata değerleri sonuçları	97
Çizelge 4.16. YELLOWSTONE GAYZER PATLAMA SÜRELERİ veri setine ilişkin sonuçlar.....	100
Çizelge 4.17. YELLOWSTONE GAYZER PATLAMA SÜRELERİ zaman serisine ilişkin performans ölçütlerinin hata değerleri sonuçları.	101
Çizelge 4.18. KANADA VAŞAĞI veri setine ilişkin sonuçlar	104

Çizelge 4.19. KANADA VAŞAĞI zaman serisine ilişkin performans ölçütlerinin hata değerleri sonuçları	105
Çizelge 4.20. UÇAK YOLCU SAYISI veri setine ilişkin sonuçlar	108
Çizelge 4.21. UÇAK YOLCU SAYISI zaman serisine ilişkin performans ölçütlerinin hata değerleri sonuçları	109



ŞEKİLLER DİZİNİ

Şekil 1.1. Biyolojik sinir hücresi.....	8
Şekil 1.2. Yapay sinir hücresi.	9
Şekil 1.3. Yapay sinir ağı.	9
Şekil 2.1. Tanjant-sigmoidal (a) ve logaritmik-sigmoidal (b) fonksiyonlar.	23
Şekil 2.2. Tek kutuplu (a) ve çift kutuplu (b) basamak fonksiyonu.....	24
Şekil 2.3. Doğrusal fonksiyon.....	24
Şekil 2.4. İleri beslemeli ağlar.....	25
Şekil 2.5. Yinelemeli ağlar.....	25
Şekil 2.6. İleri beslemeli ağları tabakalandırılmış gösterim.....	31
Şekil 2.7. İleri beslemeli ağları topolojik gösterim.	31
Şekil 2.8. Tek Katmanlı Doğrusal Algılayıcı (Perceptron).....	33
Şekil 2.9. Uyarlamalı Doğrusal Ağlar (ADALINE).	36
Şekil 2.9. XOR problemi.....	39
Şekil 2.10. Tek tabakalı doğrusal algılayıcı ve iki tabakalı doğrusal algılayıcı.	40
Şekil 2.11. XOR Problemi çözümü.....	40
Şekil 4.1 Dolar(USD)/Avro(EUR) döviz kuru grafiği.....	61
Şekil 4.2. Dolar(USD)/İngiliz Sterlini(GBP) döviz kuru grafiği	61
Şekil 4.3. Dolar(USD)/Japon Yeni(JPY) döviz kuru grafiği	62
Şekil 4.4. Doğrusal Olmayan Otoregresif veri grafiği	62
Şekil 4.5. Mevsimsel Otoregresif veri grafiği.....	63
Şekil 4.6. Sinüs veri grafiği.....	63
Şekil 4.7. Üstel veri grafiği	64
Şekil 4.8. Yellowstone gayzer patlama süreleri veri grafiği	64
Şekil 4.9. Kanada vaşağı veri grafiği	65
Şekil 4.10. Uçak Yolcu Sayısı veri grafiği.....	65
Şekil 4.11. AVRO döviz kuru için 1000 tekrara ait performans ölçütlerinin grafikleri	Error! Bookmark not defined.
Şekil 4.12. İNGİLİZ STERLİNİ döviz kuru için 1000 tekrara ait performans ölçütlerinin grafikleri.....	77

Şekil 4.13. JAPON YENİ döviz kuru için 1000 tekrara ait performans ölçütlerinin grafikleri	83
Şekil 4.14. DOĞRUSAL OLMAYAN OTOREGRESİF veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri.....	87
Şekil 4.15. MEVSİMSEL OTOREGRESİF veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri.....	91
Şekil 4.16. SİNÜS veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri	95
Şekil 4.17. ÜSTEL veri seti için 1000 tekrara ait performans ölçütlerinin..... grafikleri	99
Şekil 4.18. YELLOWSTONE GAYZER PATLAMA SÜRELERİ veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri.....	103
Şekil 4.19. KANADA VAŞAĞI veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri	107
Şekil 4.20. UÇAK YOLCU SAYISI döviz kuru için 1000 tekrara ait performans ölçütlerinin grafikleri.....	111

SEMBOLLER VE KISALTMALAR DİZİNİ

YSA	Yapay Sinir Ağları
OMH	Ortalama Mutlak Hata
MMH	Medyan Mutlak Hata
GOMH	Geometrik Ortalama Mutlak Hata
HKO	Hata Kare Ortalama
HKOK	Hata Kare Ortalama Karekökü
DDHO	Dördüncü Dereceden Ortalama Hata
OMOH	Ortalama Mutlak Orantılı Hata
MMOH	Medyan Mutlak Orantılı Hata
HKOOK	Hata Kare Ortalama Orantılı Karekökü
HKMOK	Hata Kare Medyan Orantılı Karekökü
SOMOH	Simetrik Ortalama Mutlak Orantılı Hata
SMMOH	Simetrik Medyan Mutlak Orantılı Hata
OMGH	Ortalama Mutlak Göreceli Hata
MMGH	Medyan Mutlak Göreceli Hata
GOMGH	Geometrik Ortalama Mutlak Göreceli Hata
OMÖH	Ortalama Mutlak Ölçekli Hata
HKOÖK	Hata Kare Ortalama Ölçekli Karekökü
ABÖ	Akaike Bilgi Ölçütü
BBÖ	Bayesci Bilgi Ölçütü
NS	Nash Sutcliffe Etkinlik Katsayısı
YD	Yön Doğruluğu
DYD	Değiştirilmiş Yön Doğruluğu
ABK	Ağırlıklı Bilgi Kriteri
UABK	Uyarlamalı Ağırlıklı Bilgi Kriteri
GAPK	Genişletilmiş Ağırlıklı Performans Kriteri

1. SİNİR AĞLARINA GİRİŞ

1.1. Esnek Hesaplama Yöntemleri ve Yapay Zekâ

Akıl(us) kelimesi insanların zekâ düzeyini ifade etmesine rağmen sıkça zekâyı karıştırılmaktadır. Elmas (2011)'e göre “*Akıl genetik yoldan intikal eden sevgi, korku, kıskançlık, doğal savunma güdülerinin yanı sıra bulunduğumuz çevreden aldığımız etkileşimlerden ve toplumun şartlandırmalarından etkilenerek gelişmektedir. Dolayısıyla akıl sabit değil, aksine insanın hayatının sonuna kadar artabilen ve gelişebilen bir yetenektir. Akıl makine, bilgisayar, yazılım veya başka bir yolla taklit edilemez*” biçimindedir.

Elmas (2011) “*Zekâ belirli bir konuda çalışılarak, öğretilerek, eğitilerek edinilen bilgi ve birikimle deneyimlere dayalı becerilerle geliştirilebilir. İlk kez karşılaşılan ya da ani olarak gelişen bir olaya uyum sağlayabilme, anlama, öğrenme, analiz yeteneği, beş duyunun dikkatin ve düşüncenin yoğunlaştırılması zekâ ile gerçekleştirilebilmektedir. Zekâ, yazılım veya tümleşik yongalarla taklit edilebildiğinden bu yana bu durum Yapay Zekâ olarak adlandırılmaya başlanmıştır*” biçiminde zekâyı tanımlamıştır.

Simon (1983) tarafından öğrenme kavramı, “*Zaman içinde yeni bilgilerin keşfedilmesi yoluyla davranışların iyileştirilmesi süreci*” olarak tanımlanmıştır. Öğrenme olarak tanımlanan bu süreç akıl ile zekânın gelişimini açıklar nitelikte olabilmektedir.

Zekâ gerçekte, insanların zihinsel açıdan yetkinliklerini ifade etmektir. Dolayısıyla bu yetkinlikleri ifade etmek için zekâdan ziyade zekâlardan bahsetmenin daha doğru bir yaklaşım olduğu ortaya çıkmaktadır. WAIS-3 testindeki 13 farklı testin pozitif korelasyona sahip olmaları zekâların birbirinden bağımsız olmadığını göstermektedir. Bu testi sözel kavrama, algısal düzenleme, işleyen bellek ve işleme hızı olmak üzere

4 grupta deęerlendirdiđimizde ise gruplar arasındaki korelasyon testler arasındaki korelasyondan daha yksek olduđu ortaya ıkmıřtır (Wechsler, 1955).

İnsan zekâsı ile ilgili alıřmalardan birkaçı ise řu řekilde zetlenebilir. İnsan zekâsındaki genel unsuru ilk betimleyen psikolog Charles Spearman olmuřtur. Amerikalı psikolog John Carroll 1993 yılında yayınladıđı kitabında o gne kadar kullanılan 400 veri setini tekrar analiz etmiřtir. 13 Aralık 1994 tarihinde birok psikolođun bir araya gelerek Wall Street Journal gazetesinde yayınladıkları makalede, insan zekâsı hakkında bilinenler 25 maddeyle zetlenmiřtir (Carroll, 1993).

Zekâ ile ilgili bilinen ilk ve byk aptaki arařtırma 1932 ve 1998 yıllarında yapılmıř olan İsko Zihin Arařtırmasıdır. 11 yařındayken teste tabii tutulan insanlardan 184'ne tekrar ulařılabilmıř ve aynı test tekrar uygulanmıřtır. Bulgular bu insanların 11 yařındayken testten aldıkları skorlardan, 77 yařlarına geldiklerinde aynı testten daha iyi skorlar elde etme eđiliminde olduđu sonucuna ulařılmıřtır (Deary v.d., 2000).

Zekâ testi skorları ile beynin boyutlarını ilk iliřkilendiren kiři Austin Teksas niversitesinden Lee Willerman, 1991 yılında yaptıđı alıřmada beynin boyutu ile biliřsel yetenek arasında orta dzey bir bađlantı bulmuřtur. Ortalama olarak yksek zekâya sahip insanların daha hızlı, karmařık ve farklı řekillerde elektriksel tepki verdiđi gzlemlenmiřtir (Willerman v.d., 1991).

Aynı aileye mensup kiřilere iliřkin yapılan zekâ testlerinde arpıcı sonulara ulařılmıřtır. Bu konuda ikizlere zerine yođunlařan en nemli alıřmalardan biri Minnesota Yetiřtirilmiř İbizler (MISTRA) alıřmasıdır (Bouchard v.d., 1990). Bulgulardan en dikkat ekici olanı zekânın řekillenmesinde genlerin; evre ve ailelerin yetiřtirme tarzına nazaran ok daha etkili olduđudur.

IQ testi 1905 yılında Alfred Binet ile Theophile Simon tarafından verilen normal eđitimden yuararlanamayacak ocukların belirlenmesi amacıyla geliřtirilmiřtir. IQ testleri birok alanda byk zaman ve maliyet tasarrufu sađlanmasını mmkn kılabilmektedir. rneđin iře alımlarda basit bir psikometrik testin diđer yntemlere nazaran olduka az maliyetli ve kısa zamanda sonuca ulařmayı mmkn kıldıđı gzlemlenmiřtir.

IQ testleriyle ilgili önemli bir bulgu ise zaman içerisinde normlarının sürekli geliştirilerek döneme uygun hale getirilmesi gerektiğidir. 1932 ile 1978 yıllarını kapsayan ve 1984 yılında yayınlanan, Flynn etkisi olarak da bilinen bulgular nesiller arasında 14 IQ puanı farkının olduğunu ortaya çıkarmaktadır. Buradan yola çıkarak Flynn, IQ testinin zekâyı ölçmediğini, yalnızca zekânın “soyut problem çözme yeteneği” adını verdiği bir bağıntısını ölçtüğünü söylemiştir. Buna göre, IQ testinin farklı nesiller ve farklı kültürel grupların zekâlarının güvenilir bir biçimde karşılaştırılması için kullanılamayacağı sonucuna varmıştır (Flynn, 1984).

Zekâ testleri tarafından test edilen zihinsel yetenek, kesinlikle insan beyninin yapabileceklerinin tamamı değildir ve gelecekte zekâ testleri ile ilgili cevaplandırılması gereken bir çok konu vardır (Deary, 2001).

İnsan beyni sayısal bir işlemi birkaç dakikada yapabilirken; idrak etmeye yönelik olayları çok daha kısa bir sürede yapabilmektedir. Örneğin, yolda giden bir sürücü yolun kayganlık düzeyini, ilerideki tehlikeden ne kadar uzak olduğunu nicelik bakımından ifade edemese de geçmişteki deneyimleri sayesinde hızını ayarlayabilir (Elmas, 2011). Öyle ki saniyelerle ölçülebilecek kadar kısa bir sürede tehlikeyi görebilmekte ve tepkisini gösterebilmektedir.

Bilgisayarlar çok karmaşık işlemleri hızlı biçimde çözümleyebilmelerine karşın, algılama ve deneyime dayalı bilgilerin kullanabilmesi konusunda yetersiz kalabilmektedirler. İnsan beynini farklı kılan temel özellik, sinirsel algılayıcılar yoluyla elde edilmiş ve olayın niteliğine göre kümelenmiş bilgileri hızlı bir biçimde değerlendirebilmesidir.

Uzman sistemler (expert systems), insan düşüncelerini değerlendirerek gerçek yaşama uygulamak amacıyla oluşturulan yazılımlardır ve bu sistemler geliştirilirken uzmanların bilgi ve deneyimlerini bilgisayara aktarılması amaçlanır.

Genel olarak yapay sinir ağları (YSA), insan beynindeki sinir ağlarını taklit eden bilgisayar programlarıdır. Temelde, eldeki bilgilerin paralel bilgi işleme sistemi olarak sinir ağlarında eğitilmesi işini yapmaktadır. Böylece gözlemler arasındaki ilişkileri ortaya çıkararak genelleştirme yapabilmeyi amaçlayan, sonraki adımları tahmin etmeye çalışan ve daha birçok amaç için çözümler üretilebilmektedir. (Elmas, 2011)

Esnek hesaplama teknikleri, sistemleri akıllı hale getiren yenilikçi yaklaşımlardır. Uzman sistemler, bulanık mantık, sezgisel algoritmalar, YSA gibi çalışma alanları bulunmaktadır. Gerçek yaşam problemleri bilgi, teknoloji ve metodolojiyi harmanlayan akıllı sistemlere gereksinim duymaktadır. Akıllı sistemler, bir insan gibi ustalıklı hareket edebilme, uyarlanabilme, istenilen doğrultuda çevreyi en iyi şekilde düzeltebilme, ne tür kararlar verilmesi gerektiği konusunda yönlendirici olma gibi özelliklere sahip sistemlerdir.

Lotfi A. ZADEH; “Esnek hesaplama, insan beyninin fevkalade özelliği olan mantık yürütme, çevresindeki belirsizlikleri öğrenme ve eksik bilgiyle sonuca ulaşabilme yetileri arasındaki paralellikleri hesaplamaya yarayan gelişmekte olan bir yaklaşımdır.” biçiminde bir tanımlama yapmaktadır.

Esnek hesaplama; yapay sinir ağları, bulanık küme teorisi, yaklaşımlı muhakeme, genetik algoritma, tavlama benzetimi gibi hesaplama yöntemlerini içerir. Bu metodolojilerin kusursuz kullanımı ve entegrasyonu esnek hesaplamanın çekirdeğini teşkil etmektedir. Böylece, esnek hesaplama yerine göre insan bilgisini etkin bir şekilde kullanıp, belirsizliği çözümleyerek modelleyebilmektedir. Esnek hesaplama yöntemleri geleneksel yapay zekâ yaklaşımlarını tamamlar nitelikte olan bir disiplin olarak görülebilir.

İnsanlar genellikle mantıksal düşünme ve sonuçlandırma sürecinde doğal konuşma dillerini kullanırlar. Geleneksel yapay zekâ araştırmaları, insanların davranışlarını taklit etmeye ve bunları dilsel formlarda ya da simgesel kurallar çerçevesinde ifade etmeye odaklanmıştır. Bilgiye sahip olduğu durumlarda, simgesel sistemler insan davranışlarını modellemede iyi bir temel sağlayabilirler. Çoğu başarılı yapay zekâ ürünü bilgi tabanlı ya da uzman sistemlere sahip ürünlerdir.

Yapay zekâyâ ve uzman sistemlere ilişkin pek çok tanım söz konusudur. Bunlardan bazıları aşağıda verilmektedir.

“Yapay zekâ, bilgisayarların akıllı şeyler yapmasını sağlayan bir sanattır.” (Waldrop)

“Yapay zekâ, amaca ulaşmak adına programların kurallara göre veriyi işlediği bir programlama stilidir.” (W.A. Taylor)

”Uzman sistemler, hiçbir şey hakkında her şeyi bilen uzman insan karikatürüdür.” (A. R. Mirzai)

“Yapay zekâ, bilgisayarlar gibi makinaların insanların gözlemleriyle zekâ adı verilen davranışları sergilemesini sağlayan bir aktivitedir.” (R. McLeod)

“Uzman sistemler zor problemlerin çözümünde yüksek performansa ulaşmak için uzman bilgisini kullanan bilgisayar programlarıdır.” (D.A. Waterman)

Esnek hesaplama öğelerinin “yapay zekânın modern parçaları” olarak adlandırılması kaçınılmaz bir şekilde kişisel yargıya dayanmaktadır. Bunun nedeni, yapay zekâ alanlarının sürekli gelişmesi ve esnek hesaplama ile yapay zekâ arasındaki bağın giderek belirsiz hale gelmesidir. Yapay zekâ metodolojilerinin, sonraki nesillerce daha karmaşık ve daha güçlü bir şekilde gelişeceği düşünülmektedir (Jang, Sung ve Mizutani, 2012).

Yapay zekâ araştırmalarının uzun dönemdeki amacı, makine zekâsının etkin bir şekilde kullanımının anlaşılması ve oluşturulmasıdır. Bu açıdan bakıldığında, esnek hesaplama da benzer olarak bu nihai amacı paylaşır. Beyin modelleme, evrimsel algoritmalar ve bağışıklık sistemi modelleme gibi biyolojik olarak esinlenen metodolojilere dikkatlerin çevrilmesinin nedeni olarak, doğal zekâyı kullanan biyolojik mekanizmalara benzetilmesi gösterilebilir. Bu metodolojiler bir yönüyle geleneksel yapay zekâdan ayrılmakta ve çoğunlukla sembolizmden kaynaklanan eksiklikleri karşılamaktadırlar.

Bu öğrenme işleminin bilgisayar gibi işlem yapabilen makineler tarafından yapılması ise makine öğrenmesi olarak adlandırılmaktadır. Yapay zekâyı sahip makinelerin üretilmesi sayesinde öğrenilen bilgilerin geliştirilmesi, iyileştirilmesi ve gelecekte karar verebilen mekanizmalar üretilmesi amaçlanmaktadır.

1.1.1. Esnek hesaplama yöntemlerinin karakteristikleri

Aşağıda esnek hesaplamanın temel özellikleri verilmiştir.

İnsan Uzmanlığı : Esnek hesaplamalarda, biyolojik olaylardan esinlenerek oluşturulan hesaplama modellerini kullanarak, problemleri çözmek için insan tecrübesi kullanılır.

Yenilikçi Optimizasyon Teknikleri : Esnek hesaplama yenilikçi yöntemlerin çeşitli kaynaklardan oluşmasını sağlamaktadır. Bunlar genetik algoritma, tavlama benzetimi, rastgele seçim modeli, arı kolonisi, karınca kolonisi, parçacık sürü optimizasyonu gibi tekniklerdir.

Sayısal Hesaplama : Sembolik yapay zekâdan farklı olarak esnek hesaplama çoğunlukla sayısal hesaplama dayanır.

Yeni Uygulama Alanları : Sayısal hesaplama dolayısı ile esnek hesaplama kendine bir çok gerçek hayat uygulama alanı bulmuştur. Bunlar yoğun hesaplamalar, uyarlamalı sinyal işlemleri, uyarlamalı kontrol, doğrusal olmayan sistem teşhisi, doğrusal olmayan regresyon ve örüntü tanıma gibi uygulamalar olarak özetlenebilir. Çoğu gerçek yaşam problemi büyük ölçüde ve kaçınılmaz olarak belirsizlik içermektedir. Esnek hesaplama sonucunda çoğunlukla gerçek yaşam problemlerine tatmin edici cevaplar verilmektedir.

Modelsiz Öğrenme : YSA ve uyarlamalı bulanık sistemler sadece hedef sistemin örnek verisini kullanarak model oluşturma kabiliyetine sahiptir. Hedef sistemini detaylı anlamak, model yapısını öğrenmemize yardımcı olsa da zorunlu değildir.

Yoğun Hesaplama : Problem çözümünde, bulanık sinir ağları ve esnek hesaplama kuralları bulmak ve veri içerisindeki ilişkileri yakalayabilmek için yoğun (complex) işlemlere maruz kalınmaktadır. Fakat bu durum hesaplamalı zekânın bütün alanları açısından beklenen bir durumdur.

Hedef Odaklı Çıkarım : Yapay sinir ağları ve esnek hesaplama da sonuca giden yol ne kadar uzun ya da zor olsa da sonuca ulaşabilme özelliğine sahiptir. Bu zamanı azaltma adına optimizasyon yöntemlerinden yararlanılabilse de gerekli değildir.

1.2. Sinir Ağları


İnsan beyni, doğal zekânın kaynağı ve olağanüstü çalışan paralel bir bilgisayardır. Beyin müthiş bir hızla tamamlanmamış bilgiyi işleyerek bilgileri algılayabilmektedir. Sinir hücrelerinin fonksiyonları elektronik devrelerden 10^6 kere daha yavaş olmasına rağmen insan beyni görsel ve işitsel bilgiyi modern bilgisayarlardan daha hızlı işleyebilmektedir.

Modern bilgisayarların gelişmekte olduğu günümüzde, bilim adamları gün geçtikçe makineleri daha etkin bir şekilde kullanmaya zorlayarak insanlar için kolay olan, örneklere dayanarak bir öğreticinin yardımıyla harfleri öğrenebilme ve bir kediye köpekten ayırabilme gibi işlemleri yürütebilmek için çalışmaktadırlar. Tecrübeler arttıkça yanıtlarımızı düzeltmek ve performansımızı artırmak doğrultusunda kendimizi geliştirmekte ve bu edindiğimiz tecrübelerimizi bilgisayarlara aktararak karar verebilmemiz için bazı kurallar bile geliştirebilmekteyiz. Öğretici olmadığı zamanlarda da benzer örüntüleri gruplayabilmekteyiz. Hali hazırda bir diğer ortak insan özelliği olan çeşitli kısıtlar altında kaynaklarımızı maksimum derecede kullanabilme isteğininide geliştirilen teknikler sayesinde gerçekleştirebiliyoruz (Jang, Sung ve Mizutani, 2012).

Yapay sinir ağları, insan beynine özgü yukarıda anlatılan bu özelliklere sahip sistemler olarak geliştirilmektedir.

1.2.1. Biyolojik sinir ağları


Biyolojik sinir ağları birbirleriyle bağlantılı sinir hücrelerinden meydana gelir. İnsan beyninde yaklaşık olarak 10^{10} adet sinir hücresi ve $6 \cdot 10^{13}$ ' ten fazla sayıda bağlantı olduğu düşünülmektedir.



Şekil 1.1. Biyolojik sinir hücresi.

Biyolojik sinir hücresi (Şekil 1.1.) temelde dentrit, soma, sinaps ve aksonlardan oluşur. Dentritlerin görevi, biyolojik sinir hücresine gelen sinyalleri alıp somaya iletmektir. Somaya gelen sinyaller burada işlenir ve oluşturulan sinyaller akson aracılığıyla sinapslara gönderilir. Sinapslardan çıkan sinyaller bir başka sinir hücresinin dentritleri vasıtasıyla hücreye alınır ve sinyal iletimi gerçekleştirilmiş olur. Biyolojik sinir hücrelerinde bir hücrenin çıktısı diğerinin girdisi olacak şekilde sinyal akışı milyonlarca hücre tarafında sürekli biçimde gerçekleştirilir.


Yapay sinir ağlarında ise girdi tabakası olarak adlandırılan kısım dentritlerdir ve görevleri gelen girdi değerlerini ağa alıp gizli tabakaya iletmektir. Gizli tabakaya iletilen girdi değerleri biyolojik ağlardaki somaya benzetilebilir; verinin işlendiği, aralarındaki ilişkilerin kurulduğu, öğrenme sürecinin gerçekleştiği kısım olarak adlandırılabilir. Bütün bu bilgi, sinyal akışı aksonlarla benzer görev yapan bağlantı ağırlıklarıyla taşınır ve son olarak çıktı tabakasına yani sinapslara iletilir. Temel olarak yapay sinir ağlarının biyolojik sinir ağlarıyla olan benzerliği bu şekilde açıklanabilir. Şekil 1.2. de yapay sinir hücresi gösterilmektedir.



Şekil 1.2. Yapay sinir hücresi.

1.2.2. Yapay sinir ağları

Beyin modelleyiciler sinir ağlarının özelliklerini keşfettikten sonra bu sistemi taklit eden sezgisel bir yaklaşım olan “Yapay Sinir Ağlarını” bulmuşlardır. Şekil 1.2.’ de YSA, beynin davranışlarını taklit eden birbirine bağlı bir mimari şeklinde doğrusal olmayan dinamik bir sistem olarak gösterilmektedir.



Şekil 1.3. Yapay sinir ağı.

Haykin (1994) “Yapay sinir ağı, deneyime dayalı bilgiyi depolamaya ve bu bilgiyi kullanıma sunmaya yönelik doğal bir eğilim içinde olan yoğun paralel dağıtılmış bir işlemcidir” şeklinde tanımlama yapmıştır.

YSA nöron olarak adlandırılan ve birbirine bağı yapay sinir hücrelerinden oluşur. Hücrelerin birbirine olan bağlantıları sayesinde bilgi ve sinyal akışı gerçekleşir. Bağlantılar nöronların birbirleri arasındaki bilgileri taşıyan ağırlık değerlerine sahiptir ve her bir nöronun çıktısının veri yapısını elde edebilmesi için diğer nörona iletilmeden önce bir aktivasyon fonksiyonundan geçirilir.

Yapay sinir ağlarına ilk adımlar 1940'lı yılların başlarında atılmıştır (McCulloch ve Pitts, 1943) ve insan beynini anlamaya, gücünü uygulamaya yönelik çalışmalar üzerine yoğunlaşmıştır. Yapay sinir ağlarının erken başarıları dijital hesaplama alanındaki hızlı gelişimden etkilenmiş ve gölgede kalmıştır. Ayrıca ilk geliştirilen yapay sinir ağlarının kapasitelerinin kısıtlı olması bütün alanda kötü bir etki bırakmıştır.

Werbos (1974) tarafından geri yayılım algoritmasının bulunmasıyla yeni bir dönem başladıysa da hak ettiği ilgiyi bulamamış ve Rumelhart (1986) tarafından yeniden formüle edilmesiyle geri yayılım algoritması araştırmacıların ilgisini çekmiş ve hızla araştırılmaya, geliştirilmeye başlamıştır.

YSA'nın güçlü desen algılayıcı olması ve doğrusal olmayan modelleme yeteneği çokça tercih edilmesinin ana sebeplerindendir. Diğer model tabanlı öngörü yöntemlerinin aksine YSA veri odaklı olup herhangi bir varsayım gerektirmeksizin, tahmin edilen değişkenlerle tahmin edilecek değişkenler arasındaki fonksiyonel ilişkilerle ilgilenir. Bu benzersiz niteliği sayesinde YSA, genellikle çok veriden oluşan fakat veri oluşum mekanizması çoğunlukla bilinmeyen ya da test edilmesi mümkün olmayan çeşitli finansal öngörü durumlarında sıklıkla tercih edilmektedir.

Nöron olarak adlandırılan yapay sinir hücrelerinin sahip olduğu temel unsurlar ağı oluşturan her nöron için geçerlidir. Girdi, ağırlık, birleşme fonksiyonu, aktivasyon fonksiyonu ve çıktı biçimindeki bu unsurlar aşağıdaki gibi kısaca tanımlanabilirler.

- I. Girdi : dışardan ya da başka nöronlardan iletilen bilgidir.
- II. Ağırlık : nöronlar arasındaki ilişkiyi sayısal olarak taşıyan katsayıdır.
- III. Birleşme fonksiyonu : nörona gelen girdi ve ağırlıkların birleşiminden oluşan net değerini hesaplamak için kullanılan fonksiyondur. Yaygın olarak girdi ve ağırlıkların çarpımlarının toplamı birleşme işlemi için kullanılır.
- IV. Aktivasyon fonksiyonu : nöronun girdi ve ağırlıkların çarpımlarının toplamıyla elde edilen net değerini verinin yapısına uyumlu hale getirmek ve net değerine karşılık gelen çıktıyı üretmek için kullanılır.
- V. Çıktı : aktivasyon fonksiyonuyla üretilen nihai değerdir ve başka bir nörona ya da ağına dışına aktarılır.

Yapay sinir ağları genelde 3 tabakadan meydana gelmektedir.

- I. Girdi tabakası : gelen girdileri ağına iletmekle sorumludur ve bu tabakada hiçbir işlem gerçekleşmez. Bir sinir ağında sadece bir tane girdi tabakası bulunur.
- II. Gizli tabaka : gelen bilgiler işlenir ve verinin yapısına uyumlu hale getirilir. YSA'da birden fazla gizli tabaka bulunabilir.
- III. Çıktı tabaka : gizli tabakadan gelen bilgiler birleştirilir ve gerekli işlemlerden geçerek ağına verilen girdiler için gerekli çıktıları üretir. YSA'da sadece bir tane çıktı tabakası bulunur.

Bütün tabakalar ve ağı için geçerli olan paralel bir işleyiş söz konusudur. Nöronların birbirleriyle olan bağlantılarını ve bağlantıların sahip olduğu ağırlık değerlerinin en uygun hale getirilmesi, öğrenme işlemi olarak adlandırılmaktadır.

Bilgisayarlarda bilgiler bit adı verilen 0 ve 1 rakamlarıyla temsil edilirken, YSA'da bilgiler matematiksel işlevler kullanılarak nöronlar arasındaki bağlantılarda temsil edilir. Bilgi, bilgisayarlarda belirli yerlerde saklanırken; sinir ağlarında ise bilgi bütün ağına yayılmış durumdadır. Bu duruma dağıtılmış bellek adı verilir.

Klasik bilgisayarlarda bilgi belirli bellek bölgesinden elde edilirken, sinir ağlarında çıktı değeri en uygun koşullar altında ağına bilgisine ve tecrübesine dayanarak oluşturulur. Bu duruma birleştirilmiş bellek örnek olarak verilebilir.

1.3. Sinir Ağlarının Kullanıldığı Alanlar

Yapay sinir ağlarının çalışma alanı, uygulama ve geliştirme olmak üzere yoğun biçimde disiplinler arası bir alanı kapsamaktadır. Farklı alanlara ilişkin geniş uygulamaları ve kanıtlanmış başarıları ile yapay sinir ağları gelecek için umut verici olmayı sürdürmektedir.

1.3.1. Tahmin ve öngörü

Tahmin ve öngörü kelimeleri ile belirtilen kavramlar aynı anlama geldiği düşünülse de aralarında ufak farklılıklar mevcuttur. Öngörü kelimesi bir değişkenin gelecekte alabileceği değerlerin çeşitli yöntemlerle önceden belirlenmesi olarak tanımlanabilir. Tahmin ise herhangi bir değişkenin alabileceği değerlerin yine çeşitli yöntemlerle önceden belirlenmesidir fakat tahmin için bir zaman kavramı yoktur. Elde edilecek olan değerler değişkenin geçmişte, şu an da ya da gelecekte alacağı değerler olabilmektedir. Dolayısıyla buradan her öngörü bir tahmindir ancak her tahmin öngörü değildir sonucuna ulaşmak mümkündür.

YSA ile öngörü yapılabilmesi için öncelikle geçmişe ait bilginin sayısal biçimde mevcut olması, değişkenin geçmişte gösterdiği yapının gelecekte de devam etmesi gerektiği koşulları geçerli olmalıdır. Bu sayede gözlem değerleri arasındaki ilişkiler belirlenir ve gelecekte değişkenin hangi değerler alacağı tespit edilmeye çalışılır.

Kavram farklılıkları göz önüne alındığında geleceğe dair yapılan tahmin işlemleri için öngörü kelimesinin kullanılması daha doğru olacaktır. Öngörü, değişkenin geçmiş dönemlerdeki gözlem değerlerini kullanarak aralarındaki ilişkiyi bünyesinde barındıran modeller ile elde edilir. Öngörünün elde edilmesi, modelin kurulması ve öngörü yapılması olarak iki aşamadan oluşmaktadır. Öngörüler kurulan modele göre yapılacağından dolayı model kurma aşaması çok önemlidir ve modelin doğruluğu öngörünün gerçek değerlere daha yakın olmasının ölçüsüdür.

Model kurma aşaması probleme ait gözlemlerin toplanması ile başlar. Bu gözlemlere uygun model belirlendikten sonra en uygun parametre değerleri elde edilir ve modelin uygunluğu çeşitli kriterler yardımı ile belirlenir. Bu kriterler modelin hatalarına ilişkin kriterlerdir ve eğer kurulan model uygun ya da en iyi model ise bu model kullanılarak öngörü yapılır.

1.3.1.1. Zaman serileri analizinde tahmin yöntemleri

Zaman serisi, bir değişkene ilişkin zamana göre sıralanmış gözlemlerdir. Zaman serisi analizi değişkenin geçmiş zamanda aldığı değerlerden oluşan gözlem serisini kullanarak gelecek değerlerin tahmini için bir model geliştirilmesidir.

1.3.1.2. Geleneksel zaman serileri tahmini

Doğrusal zaman serilerinde başarılı sonuçlar veren parametrik ve klasik bir yöntem olan Box-Jenkins modelleri literatürde yaygın bir şekilde kullanılmaktadır. Durağan süreçlerde ya da bazı işlemlerle durağanlaştırılan serilerde bu yöntem başarılı sonuçlar verebilmektedir. Fakat gerçek hayata ilişkin zaman serileri genellikle doğrusal değildir. Dolayısıyla doğrusal olmayan zaman serilerini modellemede farklı tekniklere ihtiyaç duyulur.

1.3.1.3. YSA ile zaman serileri tahmini

Geleneksel zaman serileri tahmini yöntemlerine alternatif olarak YSA bu alanda oldukça başarılı sonuçlar elde edebilmektedir. Çok tabakalı sinir ağlarının kullanılabileceği zaman serileri tahmininin istatistik, ekonometri, finans, meteoroloji, sismoloji, jeofizik gibi birçok uygulama alanı bulunmaktadır.

YSA, herhangi bir varsayım gerektirmeden ve bir ön bilgiye ihtiyaç duymadan, değişkenler arasındaki ilişkileri ortaya çıkaran modellemeyi gerçekleştirmek için kullanılır. Bu sebeple YSA parametrik yöntemlerden ayrılarak diğer esnek hesaplama yöntemleri gibi daha geniş çapta ve esnek modelleme yöntemleri arasındadır. YSA'da zaman serilerine dayalı tahmin problemlerinde girdiler geçmiş gözlem değerlerinden oluşurken, çıktı öngörü değerini temsil eder.

Parametrik bir yöntem olmayışından dolayı yapay sinir ağları ile en iyi modelin bulunması işlemi, literatürde yaygın olarak kullanılan deneme yanılma yöntemi ile

yapılmaktadır. Yapay sinir ağlarında ağın eğitilmesi olarak adlandırılan model kurma aşaması sonucunda eğitilen ağlardan hangisinin en iyisi olduğuna karar verilmesi işlemi iki farklı yöntemle yapılabilmektedir. Örneklem içi bilgiye ve örneklem dışı performansa dayanan bu yöntemler eğitim aşamasında kullanılan kriterler yardımı ile yapılır. Bu kriterler bilgi kriterleri ve performans kriterleri olarak adlandırılabilirler. Bilgi kriterleri, oluşturulan modeller arasından eğitim aşamasında en düşük hataya sahip olan modeli en uygun model olarak seçer. Performans kriterleri ise oluşturulan modeller arasından test kümesinde en düşük hataya sahip diğer bir deyişle en iyi tahmin değerlerini veren modeli en uygun model olarak seçer.

1.3.2. Sınıflama(Classification)

Bir veri setinde toplu ve karışık olarak bulunan gözlemleri daha önceden sınırları belirlenmiş kümelerle atama işlemine sınıflama adı verilir ve bu alanda sinir ağları oldukça geniş uygulamalara sahiptir. Denetimli öğrenme yöntemiyle çalışan sinir ağları eğitim aşaması sonrasında kolaylıkla bu işlevi gerçekleştirebilmektedirler. Sınıflama analizi için müşteri profilleri, teşhis tanısı, risk kredi değerlendirmeleri gibi pek çok örnek vermek mümkündür (Shanker v.d., 1996).

1.3.3. Kümeleme(Clustering)

Sınıflamanın aksine kümeleme yönteminde sınırlar belirli değildir ve gözlemler benzerliklere veya aralarındaki uzaklıklara göre veriler gruplara ayrılmaktadır. Denetimsiz öğrenme yöntemiyle çalışan sinir ağları, eğitim aşaması sonrasında kolaylıkla bu işlevi gerçekleştirebilmektedirler (Reyes v.d., 2013).

1.3.4. Sinyal işleme

Sinyal işleme alanında sinir ağlarının birçok uygulaması bulunmaktadır. İlk ticari uygulamalarından biri ise telefon hattındaki gürültü kirliliğini azaltmak olmuştur. Sinir ağının bir formu olan Uyarlamalı Doğrusal Ağlar (ADALINE) sinir ağı, kıtalararası

uydu bağlantılarında uzun mesafe telefon devrelerindeki uyarlamalı yankı önleyiciler olarak kullanılmıştır.

Uyarlamalı yankı önleyici fikri oldukça basittir. Uzun mesafe ağının sonunda gelen sinyal, aynı zamanda telefon sistem bileşenine ve uyarlamalı filtreye yani Uyarlamalı Doğrusal Ağlara uygulanmaktadır. Telefon sistem bileşeninin çıktısı ile Uyarlamalı Doğrusal Ağların çıktısı arasındaki fark hata olarak nitelendirilmektedir ve sinir ağının bağlantı ağırlıklarını ayarlamak için kullanılmaktadır. Bu sayede Uyarlamalı Doğrusal Ağlar, telefon sistem bileşenlerinin çıktı sinyallerindeki yankıyı silmek için eğitilmektedir. (Widrow and Stearns,1985)

1.3.5. Görüntü tanımlama

Görüntü işleme alanında oldukça ilgi çekici problemler söz konusu olmuştur. Bunlardan birisi, sinir ağlarının çokça uygulaması bulunan el yazısı tanımlama problemidir. Farklı boyutlarda, pozisyonlarda ve stillerde yazılan el yazıları bu problemi oldukça zorlaştırmaktadır.

Genel amaçlı kullanılan çok tabakalı geri yayılım ağları, el yazısı ile yazılmış posta kodlarının tanımlanması için kullanılmıştır. (LeCun v.d., 1990)

1.3.6. Ses işleme

Yüksek sesle İngilizce metin okumak oldukça zor bir iştir. Çünkü bir kelimenin doğru fonetik telaffuzu, kelimeyi oluşturan harflerin gelişine göre değişmektedir. Bu probleme ilişkin geleneksel yaklaşım bir grup harflere ilişkin standart tellafuzları içeren bazı kurallar oluşturup kalan istisnaları da bir tabloda belirtmektir (Widrow ve Lehr, 1993).

Sinir ağlarının bu alanda geniş olarak bilinen kullanımı, NETtalk adı altında Sejnowski ve Rosenberg (1986) tarafından geliştirilen çok tabakalı sinir ağıdır. Geleneksel yaklaşımın aksine NETtalk sadece doğru bir şekilde telaffuz edilerek yazılmış bir grup kelimeye ihtiyaç duymaktadır. Sinir ağı eğitim için en çok kullanılan 1000 İngilizce

kelimeye ihtiyaç duymakta ve sonrasında bu ağ yeni kelimeleri çok az hata ile okuyabilmektedir.(Fausett, 1994)

1.3.7. Ses tanımlama

Farklı konuşmacılara ilişkin konuşma tanımlama işlemi bu alandaki zor bir problem olarak nitelendirilmektedir. Kullanılan bazı sistemler kısıtlı dil bilgisi ve kelime bilgisine sahiptir ve farklı konuşmacılar için tekrar eğitime ihtiyaç duymaktadır. Çok tabakalı sinir ağları ile yinelemeli ağları kapsayan bir çok sinir ağı ses tanımlama için kullanılmaktadır ve Lippmann (1989) bu ağların karakteristiklerini özetlemiştir.

1.3.8. Optimizasyon

Üretim sektörünün en önemli unsurlarından birisi de minimum maliyet ve hammaddeyle maksimum kârı elde etmek için mevcut kısıtlar altında en iyi planlamayı yapmaktır. Yapay sinir ağları da disiplinler arası bir konu olan optimizasyon alanında çokça uygulanmakta ve geniş bir yer tutmaktadır.

1.3.9. Sağlık

Sağlık alanında sinir ağlarıyla yapılan bir çok çalışma 1980’li yıllarda Anderson tarafından geliştirilmiş ve “acil doktoru” ismini taşımaktadır (Anderson, 1986, Anderson v.d. 1990). Uygulamadaki temel fikir ise birbirleriyle semptomlar, tanılar ve tedavilerle ilişkili olan medikal kayıtları saklayan ve acil durumlarda bu ilişkilere dayalı karar veren sinir ağları oluşturmaktır.

1.3.10. Kontrol

Bir treylerin geri geri manevra yaptırılmasının oldukça zor bir hamle olduğu aşikardır. Fakat yeterince tecrübeye sahip olan bir sürücünün bu işi kolayca yapabildiği gözlemlenebilmektedir. Sinir ağlarının kontrol alanındaki uygulamalarına, treylerin

geri geri manevra yaparken direksiyonu hangi yönde, doğrultuda ve şiddette çevirmesi gerektiğinin saptanması örnek olarak verilebilir.(Nyugen ve Widrow, 1989; Miller, Sutton ve Werbos, 1990)

1.3.11. İşletme

Bir çok işletme alanında kullanılan sinir ağlarıyla ilgili bir örnek ise finans ve sigorta sektörlerine ilişkin ürün geliştirme üzerinde uzmanlaşmış sinir ağı firması olan Nestor şirketi için Collins, Ghosh ve Scofield (1988a, 1988b) tarafından ipotek değerlendirmesi için geliştirilen sinir ağıdır. Genel durumlar için belirlenmiş kurallar olsa da bazı marjinal durumlar için uzmanların kararlarına ihtiyaç duyulmaktadır. Temel fikir ise ipotek değerlendirmesindeki risk etmenlerini geçmiş tecrübeleri kullanarak eğitilen sinir ağıının kullanılmasıdır.

1.4. Tarihçe

İlk yapay nöron modeli McCulloch ve Pitts (1943) tarafından tanıtılmıştır. Araştırmacılar birçok basit nöronun bir araya gelerek oluşturduğu sinir sisteminin hesaplama gücünü artırdığını ortaya çıkarmışlardır (Hamzaçebi, 2011). Farklı nöronların ve farklı mantık fonksiyonlarının aynı anda işlenerek bu fonksiyonların bir kombinasyonunu çıktısı olarak verebilen bu sistem, ilk yapay sinir ağı olarak literatürde yerini almıştır.

Wiener (1948) istatistiksel sinyal işleme, kontrol, iletişim gibi kavramların tanıtıldığı “Sibernetik” adlı kitabını yayınlamıştır.

Hebb (1949) yapay sinir ağları için ilk öğrenme kuralını dizayn etmiştir. Hebb’s’e göre eğer iki nöron aynı anda çalışırsa aralarındaki bağlantının gücü artmalıdır. Sonrasında bilgisayar simülasyonlarının yapılmasını mümkün kılmak için bu genellemeye gerekli düzeltmeler yapılmıştır. Bu fikir Kohonen (1972) tarafından geliştirilen korelasyon matris öğrenme kuralı ile yakından ilişkilidir.

Minsky (1954) “Sinirsel Analog Destekleyici Sistemler Teorisi ve Beyin Model Problemlere Uygulanması” başlıklı doktora tezini yazmıştır. Gabor (1954) dik iniş algoritmasını literatüre katmıştır.

Rosenblatt (1958) “Perceptron” isimli tek tabakalı algılayıcıyı geliştirmiş ve tanıtmıştır. Tipik bir perceptron, ayarlanabilir bağlantı ağırlıklarıyla birbirine bağlı girdi tabakası ve çıktı nöronlarından oluşmaktadır. Perceptron öğrenme kuralı olarak iteratif ağırlık ayarlama tekniğini kullanır ve bu yöntem Hebb öğrenme kuralından daha güçlüdür. Perceptron öğrenmesi, eğer problemi çözecek ağırlıklar mevcutsa o ağırlıklara ulaşabilecek ve problemi çözecek yeteneğe sahiptir. Rosenblatt (1962) bir çok farklı perceptron tanıtmıştır ve bunlar da diğer nöron yaklaşımları gibi eşik değeri çıktı fonksiyonlarını kullanmaktadırlar.

Tek tabakalı algılayıcıların erken başarısı bir heyecan yaratmıştır fakat Minsky ve Papert (1969) tarafından yayınlanan “Perceptron” adlı kitapta iteratif öğrenme kuralının bazı mantık işlevlerinin çözümünde yetersiz olmasının matematiksel olarak kanıtlanması algılayıcılara ilişkin ümitleri sonlandırmıştır.

Widrow ve öğrencisi Hoff 1960 yılında perceptron öğrenme kuralıyla yakında ilişkili olan ve kendi adlarıyla anılan ya da en küçük kareler ya da delta kuralı adı verilen öğrenme kuralını geliştirmişlerdir. Perceptron kuralında bağlantı ağırlıkları her yanlış yanıtta ayarlanır. Delta kuralında ise çıktı ünitesi ile hedef değeri arasındaki farkı azaltacak şekilde ağırlıkları ayarlar. Bunun sonucunda en küçük ortalama hata kare ortaya çıkmıştır. Uyarlamalı Doğrusal Ağlar (ADALİNE) olarak isimlendirilen bu ağdan daha önce bahsedilmişti. Psikoloji alanında Rosenblatt (1958) tarafından geliştirilen modeller ile elektrik mühendisliği alanında Widrow ve Hoff (1960) tarafından geliştirilen modellerin benzerliği sinir ağlarının disiplinler arası doğasını kanıtlamak amacıyla gerekli ipucuyu vermektedir. Bu öğrenme kuralındaki farklılık ne kadar küçükte olsa ağın yeteneği üzerine etkisi oldukça büyük olmuştur. Widrow - Hoff öğrenme kuralı çok tabakalı sinir ağları için geri yayılım kuralının oluşmasında öncü olmuştur.

Kohonen, Anderson, Grossberg ve Carpenter 1970’li ve 1980’li yıllarda birbirlerinden bağımsız bir şekilde fakat paralel olarak ilişkisel hafıza sinir ağlarıyla ilgilenmişlerdir.

Son alıřmaları ise kendi kendine organize bir řekilde alıřan ađlardır ve bunlar ses tanımlaması uygulamaları,gezgin satıcı problemleri, mzikselsol besteleme, medikal tanı, arpım tablosu vb. zerinde uygulanmıřtır (Kohonen 1972, Kohonen 1988, Anderson 1972, Anderson v.d. 1986, Grossberg 1976, Grossberg 1982, Carpenter ve Grossberg 1985).

1970' li yılların sakın gemesinin nedenleri arasında tek tabakalı ađların XOR gibi bazı basit mantıksal sorunları ozememeleri ve ok tabakalı ađların eđitimini sađlayacak genel bir yntemin olmamasıdır. Hatalara iliřkin bilgiyi ıktı tabakasından gizli tabakaya yayarak gncelleyen yntem ilk olarak Werbos (1974) tarafından keřfedilsede geniř bir alanda tanınmamıřtır. Aynı zamanda geri yayılım algoritması Parker (1985) ve LeCun (1986) tarafından bađımsız olarak keřfedilmiřtir. Rumelhart (1986) tarafından algoritma tekrar rafine edilmiř ve tanıtılmıřtır.

Fukushima ve arkadaşları (1980) karakter tanımlama iin zel olarak bazı sinir ađları geliřtirmiřlerdir. Bunlardan birinin adı kendi kendine organize olan sinir ađı "Neokognitron" olarak adlandırılmaktadır.

Fizik dalında nobel dln alan Hopfield (1982,1984,1985 ve 1986) tarafından, belirlenmiř ađrılıklar temeline dayanan ve uyarlamalı bađlantılara sahip geliřtirilen bir dizi sinir ađı bu alandaki ilgiyi artırmakla kalmamıř sinir ađlarına olan saygıyı da arttırmıřtır. Bu ađlar iliřkisel hafıza ađları gibi hizmet etmektedir ve gezgin satıcı problemleri gibi problemlerin ozm iin kullanılmaktadır. Nobel dll bilim adamı makinelerin insanlar gibi davranmasını sađlamanın tek yolunun insan biliřinin irdelenmesinde yattıđını vurgulamıřtır.

Boltzmann makineleri ise bazı arařtırmacıların 1980'li yıllarda geliřtirdikleri deterministik olmayan sinir ađları ađrılıkların ya da aktivasyonların olasılık yođunluk fonksiyonlarına gre deđiřmesini esas aldıđı ve bayes teoremine dayanan ađlardır (Kirkpatrick v.d. 1983, Szu ve Hartley 1987, Awad ve Khanna 2015).

1.5. Genel Özellikleri

1.5.1. Öğrenme

Yapay sinir ağlarının en büyük özelliği öğrenebilme yetenekleridir. Başka bir ifadeyle, ağdaki en iyi ağırlıkların bulunması işlemidir. Ayrıca sinir ağları koşul ve istekler doğrultusunda uyarlanabilme ve esnetilebilme özelliklerini taşımaktadırlar.

1.5.2. Doğrusal olmama

Doğrusal ya da eğrisel veri yapılarının, tahmin edilebilme, türevlenebilme gibi kavramlarla belirli bir düzende seyreden bir yapıya eşleştiğini söyleyebiliriz. Fakat gerçek hayata ilişkin gözlemleri içeren veri yapıları, doğrusal ve eğrisel yapıları içerdiği gibi aynı zamanda doğrusal olmayan veri yapılarına da sahiptirler. Belirsizlik, tahmin edilememelik ve fonksiyonel olarak bazı noktalarda türev alınamaması doğrusal olmayan yapılarla çözümlemeyi zorlaştırmaktadır.

YSA aktivasyon fonksiyonları sayesinde doğrusal, eğrisel ya da doğrusal olmayan yapıları öğrenip modelleyebilmektedirler. Bu tür yapıları öğrenebilme ve tahmin yapabilme yeteneği ile YSA bu alanda oldukça başarılıdır.

1.5.3. Uyarlanabilirlik

Uyarlanabilme özelliği YSA' nın performansını belirleyen en önemli etkenlerden biridir. YSA'nın sahip olduğu parametrelerin optimal bir şekilde kullanılması ağın gerçeğe yakın sonuçlar verebilmesi için gereklidir. Diğer taraftan, parametrelerin yanlış ya da yetersiz şekilde kullanılması çok kötü sonuçlar doğurabilir. Ayrıca sinir ağları kapalı kutu olarak tanımlanan yapılardır. Yani sistem içerisindeki bilgi aktarımı nöronların birbirleriyle etkileşimleri sonucu oldukça karmaşık bir hale gelip bütün ağa yayılır. Dolayısıyla nöronların çoklu etkileşimi herhangi bir nöronun sonuca olan etkisini takip etmeyi imkansız kılar. Ayrıca sinir ağlarının karmaşık yapılar olması da bu durumu açıklar.

1.5.4. Hata toleransı

Yapay sinir ağıları hata toleransı içerir. Ağdaki nöronun silinmesi demek sistemin çökmesi anlamına gelmemektedir. Bunun yerine sistem paralel mimariye sahip olduğundan dolayı performans kalitesi kademeli olarak azalsa da çalışmaya devam etmektedir.

1.5.5. Genelleme

Genelleme yeteneği sinir ağının öğrenmesine dayanarak eğitildiği verilerden farklı olarak yeni veriler verildiğinde anlamlı sonuçlar üretebilmesidir.

1.5.6. Avantaj ve dezavantajları

Öğrenme yetenekleri ve uyarlanabilme özelliklerine ek olarak matematiksel modele ihtiyaç duymamaları, uygun maliyet ve zaman koşulları altında en uygun çözümü sunmaları, kural tabanı gerektirmemeleri ve farklı öğrenme algoritmaları kullanılabilmesine karşın bu avantajlara sahip olan sinir ağlarının bazı dezavantajları da vardır.

Başlangıçta rastgele seçilen ağırlık değerlerine bağımlı olması ve parametrik bir yöntem olmaması nedeniyle YSA her zaman optimal çözümü garanti etmemesi dezavantajları arasında sayılabilir. Ayrıca YSA kendisini oluşturan parametre bileşenlerine oldukça duyarlı sistemlerdir ve bu parametrelerin uyumlu çalışmaması sonucunda oldukça kötü sonuçlar ortaya çıkaran sinir ağları ortaya çıkabilir.

2. YAPAY SİNİR AĞLARI

Şu ana kadar çok sayıda sinir ağı modeli önerilmiş ve araştırılmıştır. Sinir ağı modelleri çeşitli kriterlere göre sınıflandırılmaktadır. Örneğin, öğrenme yöntemlerine göre denetimli ve denetimsiz öğrenme, mimarilerine göre ileri beslemeli ya da yinelemeli, çıktı tipine göre ikili ya da sürekli, nöron tiplerine göre tek düze ya da melez, uygulama alanlarına göre yazılım ya da donanım, bağlantı ağırlıklarına göre ayarlanabilir ya da sabit devreler, işlemlerine göre biyolojik ya da psikolojik etkenli gibi ve daha birçok farklı kategoriyle sınıflandırmak mümkündür.

2.1. Yapay Sinir Ağları Bileşenleri

2.1.1. Mimari yapı

Sinir ağlarının 3 ana bileşeni arasında problemin yapısına ve ulaşılması gereken amaca yönelik belirlenmesi gereken ilk ve önemli bileşen mimari yapıdır. Mimari yapı 3 ana birimden oluşmaktadır. Bunlar girdi tabakası, gizli tabaka ve çıktı tabakası olarak adlandırılabilir. Genel olarak sinir ağları sadece bir tane girdi ve çıktı tabakasından oluşmaktadır ve bunun yanında gizli tabaka sayısı birden fazla olabilmektedir. Mimari yapıyı oluşturan tabaka ve tabakalardaki nöron sayıları yapının parametreleridir. Bu parametrelerin belirlenmesi aşamasında literatürde kullanılan çeşitli yöntemler bulunmaktadır. Bunlardan en yaygın olarak kullanılanı ise kullanım kolaylığı nedeniyle deneme yanılma yöntemidir.

2.1.2. Öğrenme algoritması


Öğrenme algoritmaları YSA'nın eğitilmesi amacıyla kullanılan algoritmadır. Farklı strateji ve işlemlerden oluşan birçok öğrenme algoritması olmasına rağmen en yaygın olarak kullanılanı geri yayılım öğrenme algoritmasıdır. Temel olarak hedeflenen değer ile sinir ağının verdiği değer arasındaki farka dayalı hatanın mümkün olduğunca

küçültülmesine dayanan strateji bir çok yolla çözümlenmektedir. Levenberg-Marquadt, BFGS Quasi-Newton geri yayılım algoritmaları bu stratejilere örnek olarak verilebilir.


2.1.3. Aktivasyon fonksiyonu

Sinir ağlarının temel yapıtaşları olan nöronlar, gelen sinyalleri diğer nöronlara iletmeden önce net değeri olarak adlandırılan çıktı değerlerini aktivasyon fonksiyonları ile elde etmekte ve sinyal akışını sağlamaktadır. Aktivasyon fonksiyonunda nöronların net değerleri, verinin yapısının elde edilebilmesi amacıyla kullanılmakta ve bu sayede sinir ağları doğrusal, eğrisel ya da doğrusal olmayan veri yapılarına öğrenebilmektedir. Aktivasyon fonksiyonu olmadan YSA öğrenme işlemini gerçekleştiremez, çünkü elde edilen net değerleri ile veri yapısı arasındaki eşleme ya da haritalama (mapping) işlemi olmadan YSA sadece doğrusal bir ayırıcı olarak kalmaktadır.


En çok kullanılan bazı aktivasyon fonksiyonlarının grafikleri aşağıda verilmektedir.



Şekil 2.1. Tanjant-sigmoidal (a) ve logaritmik-sigmoidal (b) fonksiyonlar.



Şekil 2.2. Tek kutuplu (a) ve çift kutuplu (b) basamak fonksiyonu.




Şekil 2.3. Doğrusal fonksiyon.

2.2. Sinyal Akışına Göre Yapay Sinir Ağları

Bu kısımda, yapay sinir ağlarının sinyal akış şekline göre türleri tanıtılmaktadır. Bunlar ileri beslemeli ve geri beslemeli ağlardır.

2.2.1. İleri beslemeli ağlar


İleri beslemeli ağlar, iletişimin yani sinyal akışının girdi tabakasından başlayıp çıktı tabakasına doğru aynı yönde ilerlediği ağlardır. İleri beslemeli ağlarda ardışık tabakalardaki bütün nöronlar birbirleriyle bağlantılıdır.



Şekil 2.4. İleri beslemeli ağlar.

2.2.2. Geri beslemeli ağlar

Sinyal akışının ağın içinde tasarımına göre tekrarlandığı geri dönüşlerin olabildiği ağlardır. İleri beslemeli ağların aksine yinelemeli ağlarda bütün nöronlar birbirleriyle bağlantılı olmak zorunda değildir. Tabakalar arasında ya da içerisinde sinyal akışı nöronlar arasında tekrarlanabilmekte, ya da girdi tabakasından doğrudan çıktı tabakasına bağlantılar oluşturulabilmektedir.



Şekil 2.5. Yinelemeli ağlar.

2.3. Öğrenme Yöntemlerine Göre Yapay Sinir Ağları

Bu kısımda, yapay sinir ağlarının öğrenme yöntemlerine göre türleri tanıtılmaktadır. Bunlar denetimli, denetimsiz ve destekleyici öğrenme yöntemleridir.

2.3.1. Denetimli öğrenme

Denetimli öğrenme yönteminde, ulaşılmak istenilen hedef değerleri söz konusudur ve eğitilen sinir ağının üreteceği sonuçların bu hedef değerlerine oldukça yakın olması istenir. Modellemede uygulanan denetimli öğrenme algoritması, güncellenen ayarlanabilir ağırlıklar aracılığıyla kullanıcıya tatmin edici sonuçlar verebilmektedir.

Bu tip ağlar genellikle denetimli öğrenme ya da haritalama olarak adlandırılıp, girdi-hedef arasındaki ilişkiyi verilen eğitim seti çerçevesinde şekillendirmektedirler.

2.3.2. Denetimsiz öğrenme

Herhangi bir öğretici veya hedef değerleri bulunmaksızın sadece girdi değerleri ile öğrenen ağlar denetimsiz öğrenme yöntemiyle eğitilmektedir. Bu yöntemde asıl olan şey, girdi değerlerinin birbirleriyle olan ilişkileri ve aralarındaki uzaklık gibi bağıntılardır. En çok kullanıldığı alan olarak kümeleme örneği verilebilir ve önceki bölümde de belirtildiği gibi kümeleme yönteminde esas olan veriler arasındaki ilişkilerdir. Kümelerin sayısı, niteliği ve büyüklüğü gibi özellikler belirli değildir.

2.3.3. Destekleyici öğrenme

Destekleyici öğrenme yönteminde ise sinir ağının eğitiminde bir öğretici mevcuttur, fakat hedef değerleri yoktur. Sinir ağı kendi sonuçlarını üretir, fakat bu sonuçlar öğretici tarafından denetlenir ve sonuçların güncellenmesi ya da sonlandırılması hakkında karar verir. Bu öğrenme yöntemini deneme-yanılma tekniğine dayalıdır.

2.4. Öğrenme Kuralına Göre Yapay Sinir Ağları

Bu kısımda, yapay sinir ağlarının öğrenme kurallarına göre türleri tanıtılmaktadır. Bunlar çevrimiçi, çevrimdışı, gerçek zamanlı yinelemeli ve melez öğrenme kurallarıdır.

2.4.1. Çevrimiçi öğrenme

Çevrimiçi öğrenme gerçek zamanlı çalışırken aynı anda öğrenme işleminde gerçekleştiği ağlardır. Değişen karakteristiğe sahip ağlar için bu öğrenme kuralı hayatidir ve her veri tanıtımı sonrasında parametreler güncellenmelidir. Kohonen ağları bu öğrenme kuralına örnek gösterilebilir (Ritter v.d. 1992).

2.4.2. Çevrimdışı öğrenme

Delta öğrenme kuralı (Widrow – Hoff kuralı) ile çalışan sinir ağları çevrimdışı (batch) öğrenme kuralı esasına göre çalışan ağlara örnek verilebilir. Bu ağlar aynı zamanda öğrenen ve çalışan ağlardan ziyade eğitim aşaması öncelikli ve esastır. Eğitilen ağlar amaç doğrultusunda kullanılır ve yeni veriler doğrultusunda ağlar tekrar eğitilir ve tekrar kullanılır. Bu şekilde bir öğrenme, çalışma ve sonuç üretme döngüsüyle çalışan ağlar çevrimdışı öğrenme kuralına göre çalışan ağlardır (Jang, Sung ve Mizutani, 2012).

2.4.3. Gerçek zamanlı yinelemeli öğrenme

Eğer bir ağ eş zamanlı işliyorsa, bütün nöronlar çıktılarını saat sinyaline (global clock signal) göre aynı anda değiştirirler ve her bağlantıya ilişkin zaman gecikmesi bulunur. Bu eş zamanlama her nöronun çıktısına t zaman argümanı koyularak yansıtılır.

Zaman içinde geri yayılım, eş zamanlı işleyen ağların kullanımında genellikle ayrık bir zaman aralığında verilen yörüngeye göre nöronların çıktılarını veren bir dizi parametrenin belirlenmesiyle ilgilenilir. Yörünge takibi problemini çözmek için

genellikle zaman açılımı olarak adlandırılan yöntemi kullanarak maksimum T değerini geçmeyecek şekilde t zaman değişkeni ile yinelenen ağırları ileri beslemeli olanlara dönüştürülür. Bu fikir, ilk olarak Minsky ve Papert (1969) tarafından tanıtılmış ve Rumelhart (1986) tarafından geri yayılım ile birleştirilmiştir.

Zaman içinde geri yayılım, genellikle birçok problem için çok iyi çalışır fakat T zaman aralığının çok uzun olmasından kaynaklanan durumlarda hesaplamaların uzun sürmesi ve hafıza gerekliliklerinin artmasından dolayı zorluklar yaşanabilmektedir.

Dolayısıyla uzun aralıklarda ya da sonsuz aralıklarda çevrimiçi öğrenme yerine gerçek zamanlı yinelemeli öğrenme kullanılarak parametreler, sonlanan her bir döngüden sonra değil ağ çalışırken güncellenir.

Burada her nöronun çıktısının zaman indeksine bağlı hata sinyalleri olduğunu varsayıp, ağı hata sinyalini ise bu sinyallerin toplamı olarak ifade edilirse, eğer her döngüden sonra hata sinyalini küçültmek yerine çıktıların zaman indeksine bağlı hata sinyallerini her adımda küçültmek, hesaplama ve hafıza gereklilikleri bakımından tasarruf edilmesini sağlar.

Her adımda çıktıların zaman indeksine bağlı hata sinyallerini küçülterek yöntümü (gradyan) vektörünü elde edebileceğimiz için döngünün sonunu beklemeye gerek kalmaz. Fakat öğrenme işlemi genellikle daha uzun sürer.

2.4.4. Melez öğrenme kuralı : dik iniş ve en küçük kareler

Uyarlamalı ağı parametrelerini belirlemek için geri yayılım ya da dik iniş uygulayabilmemize rağmen, bu basit optimizasyon yöntemini yakınsaması genellikle çok zaman alır. Fakat bir uyarlamalı ağı sadece bir tane çıktısı olduğunu varsayarsak, ağı bazı parametrelerinin çıktısı doğrusaldır; böylece bu doğrusal parametreleri en küçük karelerle belirleyebiliriz. Bu yaklaşım dik iniş ile en küçük karelerden oluşan ve parametrelerin hızlı belirlenmesini sağlayan melez bir öğrenme kuralı oluşturur.

2.5. Uyarlamalı Sinir Ağları

2.5.1. Giriş

Bu bölümde uyarlamalı sinir ağlarının mimarileri ve öğrenme prosedürleri açıklanacak ve neredeyse bütün sinir ağı çeşitleri denetimli öğrenme kabiliyeti altında birleştirici bir çerçevede sınıflandırılacaktır. Uyarlamalı sinir ağlarının temelleri bize diğer çeşitli ağları anlamamızda kilit anahtar rolü oynayacaktır.

Uyarlamalı ağ, birbirlerine bağlı nöronlar içeren bir ağ mimarisinden oluşmaktadır. Her nöron bir işlem birimidir ve nöronlar arasındaki birliktelikler ise birbirine bağlı bu nöronları arasındaki ilişkileri göstermektedir. Nöronların her birinin ya da bazılarının uyarlanabilir olması demek, aslında çıktının bu nöronlardaki değişken parametrelere bağlı olması anlamına gelir. Öğrenme süreci, aslında istenilen çıktı değerleriyle elde edilen çıktı değerleri arasındaki farkı minimum yapacak şekilde matematiksel işlemlerle parametreleri optimize etmektedir. Diğer bir ifadeyle, görevi uygun mimari ve parametreleri belirleyerek girdi-çıkı veri ikilileri arasındaki bilinmeyen hedef sistemlerinin bulunmasıdır.

Uyarlamalı ağlarda temel öğrenme kuralı iyi bilinen “dik iniş” yöntemidir. Bu yöntem sistematik bir şekilde yöntürev vektörünün hesaplanması ve bağımsız olarak Bryson and Ho (1969), Werbos (1974) ve Parker (1982) tarafından önerilmiştir. Yapay sinir ağlarıyla ilgili araştırmaların daha başlangıç döneminde olunmasından dolayı yapılan bu erken çalışmalar yeteri kadar dikkat çekememiştir. 1986 yılında Rumelhart vd. aynı prosedürü çok tabakalı sinir ağlarındaki yöntürevi bulmak için kullanmıştır. Onların prosedürleri “Geri Yayılım Öğrenme Kuralı” olarak adlandırılmıştır. Bu isim yaygın bilinen bir hale gelmiştir, çünkü YSA ilgili araştırmalara olan ilgiyi arttırmıştır. Bu bölümde, yöntürev vektörünü bulmak için Werbos’un orijinal geri yayılım yöntemi ve öğrenme işlemini hızlandırmak için en küçük kareler yöntemiyle birlikte kullanılan geliştirilmiş versiyonu tanıtılacaktır.


2.5.2. Uyarlamalı ağ mimarisi

Adından da anlaşıldığı gibi uyarlamalı ağlar girdi-çıkı davranışının bir dizi ayarlanabilir parametrelerle belirlendiği ağ mimarisidir. Özellikle, uyarlamalı ağların yapılandırılması bir dizi nöronların doğrudan bağlantılarla birbirlerine bağlanması olarak açıklanabilir. Her nöron statik bir fonksiyona sahip olup gelen sinyali işleyip nöron çıkışına dönüştürür ve her bağlantı bir nörondan diğerine olan sinyal akışının yönünü belirler. Çoğunlukla, nöron fonksiyonları ayarlanabilir parametrelere sahip fonksiyonlara sahiptirler ve bu parametreleri değiştirerek nöronların fonksiyonlarını ve aynı zamanda uyarlamalı ağların genel davranışını da değiştirebilir.

İlk olarak uyarlamalı ağdaki tüm nöronların girdilerden çıktılara statik eşleme yaptığını, yani çıktılarının sadece girdilere bağlı olduğunu, nöronların herhangi bir dinamiğe sahip olmadığı varsayalım. Dahası öğrenme algoritmalarının gelişiminin kolaylaştırılması için bütün nöron fonksiyonlarının türevlenebilir olduğu kabul edilir. Genel olarak, uyarlamalı ağlar heterojendir; yani bütün nöronlar farklı fonksiyonlara sahip olabilir. Uyarlamalı ağlardaki bağlantılar nöronların çıktılarının yayılımının yönünü belirlemede nadiren kullanılırlar; genelde bağlantılarla ilişkilendirilmiş ağırlıklar ya da parametreler yoktur.


Uyarlamalı ağların parametreleri noktalara dağıtılmış biçimdedir; yani her nöron kendi yerel parametre kümesine sahiptir. Bu yerel parametre kümelerinin birleşimi ağın genel parametre kümesini oluşturur. Eğer nöronun parametre kümesi boş değilse bu nöronun fonksiyonunun parametre değerlerine bağlı olduğu anlamına gelir ve kare şekli bu tarz uyarlamalı nöron olduğu anlamına gelmektedir. Diğer yandan eğer nöron boş parametre kümesine sahipse fonksiyonunun değişmez olduğu anlamına gelir ve yuvarlak şekli değişmez nöronu belirtmek için kullanılmıştır. Her uyarlamalı nöron, bir ya da daha fazla parametre ilavesiyle değişmez hale getirilebilir.

Tabakalandırılmış gösterimde, aynı tabadaki nöronların birbirleri arasında bağlantıları yoktur ve tabadaki bütün çıktı nöronları bir sonraki tabakadaki nöronlara bağlıdır. Bu gösterim çoğunlukla modüleritisinden dolayı tercih edilir ve aynı tabakadaki bütün nöronlar aynı fonksiyonelliğe sahiptir.



Şekil 2.6. İleri beslemeli ağları tabakalandırılmış gösterim.

İleri beslemeli ağların bir diğer gösterimi ise topolojik sıralı gösterimidir. Bu gösterimde nöronlar sıralı bir şekilde birbirine bağlıdır ve $i \geq j$ olduğu yerlerde i . nöron ile j . nöron arasında bağlantı yoktur. Topolojik gösterim, tabakalı gösterime göre daha az modülerdir fakat öğrenme kurallarının formülasyonunu kolaylaştırmaktadır. Topolojik sıralı gösterimin tabakalı gösterimin özel bir şekli olduğunu ve her nöronun kendi tabakasını oluşturduğunu söyleyebiliriz.



Şekil 2.7. İleri beslemeli ağları topolojik gösterim.

Kavramsal olarak, ileri beslemeli ağlar aslında girdi ve çıktı arasında statik eşleşme yaparlar. Eşleşme, basit doğrusal ilişkilere ya da yüksek derecede doğrusal olmayan


ilişkileri içeren ağın mimarisine ve nöronların fonksiyonelliğine göre yapılır. Burada amaç veri setinde bulunan girdi-çıkı çiftlerinin hedef sistemi olarak kullanılıp doğrusal olmayan eşleşme yoluyla bir ağı inşa edilmesidir. Bu veri seti genellikle eğitim kümesi olarak adlandırılıp ağı performansını artırmak amacıyla parametrelerin ayarlanması işlemine ise öğrenme süreci denir. Genellikle ağı performansı aynı girdilerle, istenen çıktı değeriyle ağı çıktısı değerinin arasındaki uyumsuzluğa göre ölçülür. Bu uyumsuzluk hata ölçütü olarak adlandırılır ve farklı formlarda farklı uygulama şekillerinde olabilir. Genel olarak, öğrenme kuralı hata ölçütüne uygulanan belirli optimizasyon teknikleriyle oluşturulur.

2.6. Tek Tabakalı Algılayıcılar

Bu kısımda tek tabakalı algılayıcılar hakkında detaylı bilgiler verilecektir.

2.6.1. Giriş

Rosenblatt (1962) ilk olarak tekli doğrusal algılayıcıları desen sınıflandırılmasında kullanmasından bu yana sinir ağları araştırmacılar tarafından geniş çapta ilgi görüp, çalışmalar yapılmış ve yapılmaktadır. Fakat Minsky ve Papert (1969) yayınladıkları “Perceptrons” adlı kitapta tek tabakalı sistemlerin yetersiz olduklarını ve çok tabakalı sistemler hakkındaki kötümser bakış açısı doğrultusunda, sinir ağlarına olan ilgi 1970’lerde oldukça azalmıştır. Son zamanlarda, yeni öğrenme algoritmalarının bulunmasıyla yapay sinir ağları iyice canlanmıştır. Şekil 2.8. de tek katmanlı doğrusal algılayıcı gösterilmektedir.



Şekil 2.8. Tek Katmanlı Doğrusal Algılayıcı (Perceptron).

2.6.2. Tek katmanlı doğrusal algılayıcı (perceptron)

Tek katmanlı doğrusal algılayıcı (perceptron) olarak adlandırılrsa da esasen denetimli öğrenme yöntemiyle ikili sınıflayıcı olarak geliştirilen bir algoritmadır. Doğrusal tahmin fonksiyonu kullandığı için tek katmanlı doğrusal algılayıcı olarak adlandırılmaktadır.

2.6.2.1. Mimari yapı ve öğrenme kuralı

Basit içeriklere sahip olarak akıllı ve kendi kendine öğrenebilen sistemlerin ilk oluşumlarından biri tek katmanlı doğrusal algılayıcılardır. İlk olarak McCulloch ve Pitts (1943) tarafından biyolojik beyin nöron modeli olarak tanıtılmıştır. Ardından Rosenblatt (1962) tek katmanlı doğrusal algılayıcıları biyolojik görüntü sistemlerinin desen tanıma yeteneğini açıklamak ve modellemek amacıyla tasarlamıştır.

Öğrenme süreci uygun ağırlık değerlerinin ve eşik değerinin belirlenmesiyle başlar. İki aşamalı “öyle ya da değil” problemi için çıktı tabakası genellikle bir tane nörondan oluşur. Çok aşamalı problemler için ise sınıf sayısı kadar nöron çıktı tabakasında bulunur ve çıktı değerleri en yüksek değeri aldıkları uygun sınıfa yerleştirilir.

Girdi tabakasındaki her nöron sabit bir atama fonksiyonuna sahiptir ve girdi desenini $\{0,1\}$ ya da $\{-1,1\}$ olmak üzere ikili değerlere dönüştürür. Eğer desende bir girdi değerine karşılık gelen hücre aktifse 1, değilse 0 değerini alır. Kısıtlayıcı ise -1 değeri kullanılır. Çıktı birimi ise önceden belirlenmiş doğrusal eşik değerini içerir. Ağırlık değerleri, girdi sinyalleri ve yan terimiyle ilişkilendirilir. Burada yan terimi eşik

değerinin negatif hali olarak düşünülebilir. Tek katmanlı doğrusal algılayıcıların aktivasyon fonksiyonu olarak signum fonksiyonu ya da adım fonksiyonu kullanılır.

Girdi tabakasında girdi desenini belirleyen fonksiyon değişkenlik gösterebilir ama öğrenme işlemi sadece bağlantı ağırlıklarının çıktı birimlerine iletilmesini gerçekleştirir. Sadece çıktı tabakası değiştirilebileceğinden dolayı tek katmanlı olarak adlandırılır. Başlangıç aşamasında rastgele olarak atanan ağırlıklar ile birlikte eğitim seti belirlendikten sonra tek katmanlı doğrusal algılayıcının verdiği her yanlış yanıt, hedef çıktısı ve öğrenme oranına göre güncellenir. Eşik değerinin de sürekli güncellenerek ilerlediği öğrenme kuralı ağırlıkların öğrenme işlemi bitene kadar sürer. Öğrenme oranı sabit ya da değişken olabilir. Hatayla birlikte değişen öğrenme kuralı genellikle daha hızlı yakınsasa da istikrarsız öğrenmeye neden olur.

Öğrenme algoritmasının temeli kabaca dik iniş yöntemine dayanır. Rosenblatt (1962), ağırlıkları istenilen çıktı değerlerine göre yakınsayan bir yöntemin var olduğunu fakat bunun ancak ve ancak bu ağırlıklar kümesinin var olması koşuluyla sağlanacağını kanıtlamıştır. Buna; tek katmanlı doğrusal algılayıcı yakınsama teoremi denmektedir.

2.6.2.2. Tek katmanlı doğrusal algılayıcı algoritması

Algoritma tekli ya da ikili girdi vektörleri için uygun olup, ikili hedef, sabit θ (eşik değeri) ve ayarlanabilir yan değerini içerir. Eşik değeri adım fonksiyonuyla aynı işleve sahip değildir. Dikkat edilmelidir ki, sadece sıfırdan farklı olan aktif girdi birimlerine bağlı ağırlıklar güncellenmektedir. Ayrıca ağırlıklar sadece doğru y değerini üretemeyen örüntüler için güncellenmektedir. Bu durum doğru yanıt veren eğitim örüntüleri arttıkça daha az öğrenmenin ortaya çıkması anlamına gelmektedir.

Adım 1 Ağırlıklar ve yan değeri belirlenir.

(Basit olması amacıyla başlangıç değerlerine sıfır atanır.)

Öğrenme oranı α olarak ayarlanır ($0 < \alpha \leq 1$).

(Basit olması amacıyla α değerine 1 atanır.)

Adım 2 Durdurma koşulu sağlanmıyorsa sürece Adım 3-7 uygulanır.

Adım 3 Her eğitim ikilisi $k : l$ için Adım 4-6 yapılır.

Adım 4 Girdi değerleri için aktivasyonlar ayarlanır:

$$x_i = k_i.$$

Adım 5 Çıktı yanıt değeri hesaplanır:

$$y = b + \sum_i x_i w_i ;$$

$$y = \begin{cases} 1 & \text{eğer } y > \theta \\ 0 & \text{eğer } -\theta \leq y \leq \theta \\ -1 & \text{eğer } y < -\theta \end{cases}$$

Adım 6 Eğer hedef ile çıktı arasında hata oluştuysa ağırlıklar ve yan güncellenir.

Eğer $y \neq l$

$$w_i(\text{yeni}) = w_i(\text{eski}) + \alpha x_i,$$

$$b(\text{yeni}) = b(\text{eski}) + \alpha l.$$

Aksi halde

$$w_i(\text{yeni}) = w_i(\text{eski}),$$

$$b(\text{yeni}) = b(\text{eski}).$$

Adım 7 (Test durdurma koşulu)

Eğer bağlantılar Adım 3'te değişmezse, işlem durdurulur. Aksi halde, devam edilir.

Aktivasyon fonksiyonundaki eşik değeri negatif olmayan sabit bir değerdir. Çıktı birimindeki aktivasyon fonksiyonunun biçimi pozitif yanıt ile negatif yanıtı birbirinden ayırabilen şekildedir. Ayrıca dikkat edilmesi gereken bir nokta da sadece tek bir ayırma çizgisinin olmadığı, bunun yerine sıfır ile pozitif değerleri ve sıfır ile negatif değerleri birbirinden ayıran iki çizginin olmasıdır.

$$w_1 x_1 + w_2 x_2 + b > \theta,$$

$$w_1 x_1 + w_2 x_2 + b < -\theta.$$

2.6.3. Uyarlamalı doğrusal ağlar

Uyarlamalı doğrusal ağlar ilk olarak Widrow ve Hoff (1960) tarafından kendi kendine öğrenen ve verilen göreve uyarlanabilen en basit yapay zekâ sistemi olarak önerilmiştir. Basit fiziksel bir deney uyarlamasında girdi sinyalleri, voltajlar ve ağırlıklar da kontrol edilebilir iletken dirençlerdir. Ağın çıktısı ise girdi voltajlarının yarattığı akımların toplamıdır. Amaç istenilen girdi-çıkı ilişkisini verebilecek ağırlıkların bulunması işlemidir. Şekil 2.9. da uyarlamalı doğrusal algılayıcı gösterilmektedir.



Şekil 2.9. Uyarlamalı Doğrusal Ağlar (ADALINE).

2.6.3.1. Mimari yapı ve öğrenme kuralı

Doğrusal bir model olması nedeniyle, en küçük kareler yönteminin kolayca uygulanabileceği bu uyarlamalı ağlarda yoğun bir işlem süreci olduğundan, basit olsa bile fiziksel olarak bu yöntemin uygulanması imkânsız hale gelmektedir. Widrow ve Hoff bunun üstesinden gelebilmek için ağırlıkların ayarlanmasına ilişkin delta kuralını bulmuşlardır. Her girdi-çıkı ikilisi için hedef değerleriyle çıktı değerlerinin aralarındaki farkların karelerinden oluşan hata ölçütünün, ağırlıklara göre

türevlerinden oluşan hata vektörü, dik iniş yöntemiyle minimum değerlere ulaşmaya dek güncellenir.

Güncelleme formülü hedef değerinin çıktı değerinden büyük olduğu durumda, çıktı değerini artırmak adına pozitif girdiler için ağırlık değerini artırır; negatif girdiler için ise ağırlık değerini azaltır. Tam tersi durumda da aynı çıkarım uygulanarak delta kuralı işletilir.

Delta kuralı, basitlik, dağıtılmış öğrenme ve çevrimiçi özelliklerine sahiptir.

Dağıtılmış öğrenme, öğrenme sürecinin ağırlık merkez kontrolünden bağımsız olarak her nöron için uygulanabilirliğini ifade etmektedir.

Çevrim içi (desen desen öğrenme) olması, her desenden sonra ağırlıkların güncellenmesi demektir.

Bu özellikler sayesinde, uyarlamalı doğrusal ağlar delta kuralıyla beraber basit donanımsal uygulamalar için uygun hale gelmektedir.

2.6.3.2. Uyarlamalı doğrusal ağlar algoritması

Adım 1 Ağırlıklar belirlenir.

(Genellikle küçük rastgele sayılar tercih edilir.)

Öğrenme oranı α belirlenir.

Adım 2 Durdurma koşulu geçersiz olana kadar adım 3-7 uygulanır.

Adım 3 Her eğitim ikilisi $k : l$ için Adım 4-6 uygulanır.

Adım 4 Girdi değerleri için aktivasyon değerleri ayarlanır:

$$x_i = k_i.$$

Adım 5 Çıktı yanıt değeri hesaplanır:

$$y = b + \sum_i x_i w_i ;$$

Adım 6 Yan ve ağırlık değerleri güncellenir, $i=1, \dots, n$:

$$b(\text{yeni}) = b(\text{eski}) + \alpha(l - y).$$

$$w_i(\text{yeni}) = w_i(\text{eski}) + \alpha(l - y)x_i,$$

Adım 7 Durdurma koşulu test edilir:

Eğer adım 3'teki en büyük ağırlık değişimi belirlenen tolerans değerinden küçükse işlem durdurulur, değilse devam edilir.

1960 yıllarında birden fazla uyarlamalı ağırları birbirine bağlayarak bazı doğrusal olmayan ayrılabilir mantık fonksiyonlarının uygulanması denenmiştir. Xor probleminin çözümü için iki tane uyarlamalı ağ birbirine bağlanarak çözüm denense de, tek katmanlı doğrusal algılayıcılar gibi sonuçta tek katmandan oluştukları için yetersiz kalmışlardır.

2.6.4. XOR problemi

1960'ların ilk yıllarında tek katmanlı doğrusal algılayıcılar oldukça fazla ilgi çekmiş ve kendi kendine öğrenebilen akıllı sistemlerin inşa edilmesine yönelik pozitif bir ilgi yaratmıştır. Fakat Minsky ve Papert'in (1969) "Perceptrons" adlı kitabı yayımlandıktan sonra tek katmanlı algılayıcılara olan ilgi oldukça azalmıştır. Ayrıntılı olarak tek katmanlı doğrusal algılayıcıları analiz etmişler ve bu algılayıcıların sadece oyuncak problemleri çözebileceğini daha fazlasını yapamayacağı sonucuna varmışlardır. Ulaştıkları en cesaret kırıcı sonuç ise tek katmanlı algılayıcının basit bir XOR fonksiyonunu dahi yapamayacağıdır. XOR işlemi kısaca; iki örnek küme olan A ve B arasında "A veya B ama A ve B değil" bağlantısının olmasıdır. Biraz daha açacak olursak, olaylardan birisinin olması ama ikisi aynı anda olmaması koşuluyla olarak açıklanabilir.


XOR, sinir ağırları literatüründe en basit ve çok bilinen desen tanıma problemidir. İşleme ait doğruluk tablosu Çizelge 2.1.'de verilmiştir.

Çizelge 2.1. XOR işlemi.

A	B	Çıktı
0	0	0
0	1	1
1	0	1
1	1	0

Çizelge 2.1.'de görüldüğü üzere iki kutuplu XOR problemi basitçe bütün 1'lerin -1 ile değiştirilmesiyle elde edilir.

XOR problemi Şekil 2.9.'de görüldüğü üzere doğrusal olarak ayrılması mümkün değildir.



Şekil 2.9. XOR problemi.

Diğer bir deyişle iki farklı bölgede aynı tür veri noktalarını içeren iki boyutlu girdi uzayının doğrusal olarak ayrılması mümkün değildir. Simgesel olarak tek katmanlı algılayıcının bu problemi çözmek için aşağıdaki dört eşitsizliği de sağlaması gerekir.


$$0 \times w_1 + 0 \times w_2 + w_0 \leq 0 \Leftrightarrow w_0 \leq 0, \quad (2.1)$$

$$0 \times w_1 + 1 \times w_2 + w_0 > 0 \Leftrightarrow w_0 > -w_2, \quad (2.2)$$

$$1 \times w_1 + 0 \times w_2 + w_0 > 0 \Leftrightarrow w_0 > -w_1, \quad (2.3)$$


$$1 \times w_1 + 1 \times w_2 + w_0 \leq 0 \Leftrightarrow w_0 \leq -w_1 - w_2, \quad (2.4)$$

Fakat görüldüğü üzere eşitsizlikler eşanlı olarak düşünüldüğünde kendi içlerinde çelişmektedirler. Fakat bu problemi iki tabakalı doğrusal algılayıcıyla çözmek mümkündür.



Şekil 2.10. Tek tabakalı doğrusal algılayıcı ve iki tabakalı doğrusal algılayıcı.

Şekil 2.10.'da görüldüğü üzere iki tabakalı doğrusal algılayıcı sayesinde desenleri birbirinden ayıran iki farklı çizgi ile XOR problemi çözülebilmektedir.



Şekil 2.11. XOR Problemi çözümü

2.7. Çok Tabakalı Algılayıcılar ve Geri Yayılım Algoritması

Bu kısımda çok tabakalı algılayıcılar ve geri yayılım algoritması hakkında detaylı bilgiler verilecektir.

2.7.1. İleri beslemeli ağlar için geri yayılım ve sıralı türev

Bu öğrenme kuralının ana fikri, parametreyle ilgili olan hata ölçütlerine ilişkin türevleri olarak adlandırılan öğelerden oluşan yöntürev vektörlerini sırasıyla elde etmek olarak açıklanabilir.

Bu öğrenme kuralı, kalkülüs kitaplarında bulunabilecek olan zincir kuralıyla karmaşık formüllerin farklılaştırılarak yapılmasıyla mümkündür. Ağ mimarisindeki yöntürev vektörünün bulunma işlemi geri yayılım olarak adlandırılır. Çünkü yöntürev vektörü çıktı tabakasındaki nöronlardan tersi yönünde bir doğrultuda hesaplanır. Yöntürev vektörü oluşturulduktan sonra türev tabanlı optimizasyon yöntemleri ya da regresyon teknikleriyle parametreler güncellenir. Özellikle, eğer yöntürev vektörü dik iniş yönteminde kullanılırsa, elde edilen sonuç “Geri Yayılım Öğrenme Kuralı” olarak adlandırılır.

Eğitim kümesi p girdiden oluştuğu varsayılınsın, eğitim kümesindeki her p için hata kare ortalamaları aşağıdaki şekilde hesaplanır.

$$E_p = \sum_{k=1}^N (d_k - x_{L,k})^2 \quad (2.5)$$


burada d_k , p . hedef vektörünün k . bileşenini ve $x_{L,k}$ ise p . girdi vektörü tarafından ağda üretilen çıktı değerinin k . bileşenidir. Görüldüğü üzere E_p ’nin sıfıra eşit olması demek, hedeflenen çıktı değerleriyle ağın çıktı değeri arasındaki farkın sıfır olması demektir ve bu noktada ağ, eğitim kümesindeki değerler için istenen çıktı değerlerine

ulaşabilmektedir. Buradaki süreç, ağıın genel hata ölçütünü minimum yapmaktır. Kısacası $E = \sum_{p=1}^P E_p$ olmasıdır.

Hata ölçütüne ilişkin formülasyon genel geçer değildir, belirli durumlara ve uygulamalara göre değişebilmektedir. Dolayısıyla genellemeye ilişkin gösterimlerden kaçınılması gerekmektedir. Ayrıca hata ölçütü sadece çıktı tabakasındaki nöronların sonuçlarına bağlıdır.

Dik iniş yöntemini kullanarak hatayı minimum yapmak için öncelikle yöntürev vektörünü elde edilmelidir. Yöntürev vektörü hesaplamadan önce nedensel ilişkiler gözlemlenmelidir.

Nedensel ilişkiler ile ifade edilen şey α parametresinin değiştirmesi; çıktı tabakasındaki α parametresini içeren nöronların değiştirilmesi; ağıın çıktıların değiştirilmesi ya da hata ölçütünün değiştirilmesidir.



Diğer bir değişle α parametresindeki en ufak bir değişiklik, α parametresini içeren bütün çıktıları dolayısıyla ağıın sonuçlarını ve hata ölçütlerini etkilemektedir. Sonuç olarak, yöntürev vektörünün hesaplanmasındaki temel kavram, çıktı tabakasından başlayarak geriye doğru girdi tabakasına ulaşana kadar türev bilgisi formunun akışını sağlamaktır.

Dolayısıyla hata sinyali $\epsilon_{l,i}$, l . tabakadaki i . nöronun çıkıtısına göre hata ölçütü E_p 'nin türevi olarak doğrudan ya da dolaylı bütün bağlantıları göz önüne alarak tanımlanmıştır.

$$\epsilon_{l,i} = \frac{\partial^+ E_p}{\partial x_{l,i}} \quad (2.6)$$

Bu gösterim Werbos (1974) tarafından “Sıralı Türev” olarak adlandırılmıştır. Sıralı türev ile sıradan kısmi türev arasındaki fark ise türevlenecek olan fonksiyona nasıl

bakıldığıdır. Nöron içerisindeki çıktı için türev hesaplandığında hata ölçütünün nöronun çıktısına bağlı olmadığından dolayı sonuç sifira eşittir. Fakat hata ölçütü nöronun çıktısına dolaylı olarak bağlıdır. Çünkü nöronun çıktı değeri dolaylı yollarla çıktı tabakasını ve hata ölçütünün değerinin değiştirilmesine neden olur. Sonuç olarak, hata sinyali bu iki değişikliğin sonsuz derecede küçük olduğu durumdaki oranları olarak görülebilir.

Sıralı türev ve parçalı türev arasındaki fark incelenirse;

$$\begin{cases} z = g(x, y) \\ y = f(x) \end{cases} \quad (2.7)$$

burada z , x ve y 'nin fonksiyonu ve y , x 'in bir fonksiyonudur.

$$\frac{\partial z}{\partial x} = \frac{\partial g(x,y)}{\partial x} \quad (2.8)$$

Olağan parçalı türev işlemi için diğer bütün parametreler sabit kabul edilir. Diğer bir deyişle g fonksiyonu x ve y 'den oluşurken, burada y 'nin aslında x 'in bir fonksiyonu olduğu göz ardı edilmektedir. Sıralı türev alırken ise bu ilişkiler de dikkate alınır.

$$\frac{\partial^+ z}{\partial x} = \frac{\partial g(x,f(x))}{\partial x} = \frac{\partial g(x,y)}{\partial x} \Big|_{y=f(x)} + \frac{\partial g(x,y)}{\partial y} \Big|_{y=f(x)} \frac{\partial f(x)}{\partial x} \quad (2.9)$$

Sonuç olarak, sıralı türev doğrudan ve dolaylı ilişkileri de dikkate alarak nedensellik ilişkisini gerçekleştirir.

Hata sinyali L . tabakanın i . nöron çıktısı için aşağıdaki gibi hesaplanır.

$$\epsilon_{L,i} = \frac{\partial^+ E_p}{\partial x_{L,i}} = \frac{\partial E_p}{\partial x_{L,i}} \quad (2.10)$$

$$\epsilon_{L,i} = \underbrace{\frac{\partial^+ E_p}{\partial x_{L,i}}}_{l. \text{ tabakadaki hata sinyali}} = \sum_{m=1}^{N(l+1)} \underbrace{\frac{\partial^+ E_p}{\partial x_{l+1,m}}}_{l+1. \text{ tabakadaki hata sinyali}} \frac{\partial f_{l+1,m}}{\partial x_{L,i}} = \sum_{m=1}^{N(l+1)} \epsilon_{l+1,m} \frac{\partial f_{l+1,m}}{\partial x_{L,i}} \quad (2.11)$$

Hata sinyali $0 \leq l \leq L - 1$ aralığında zincir kuralı ile bu şekilde hesaplanır. Yöntürev vektörü de aynı yöntemle α parametresi için elde edilir.

$$\frac{\partial^+ E_p}{\partial \alpha} = \frac{\partial^+ E_p}{\partial x_{l,i}} \frac{\partial f_{l,i}}{\partial \alpha} = \epsilon_{l,i} \frac{\partial f_{l,i}}{\partial \alpha} \quad (2.12)$$

α parametresi farklı nöronlar arasında paylaştırıldığında daha genel bir formül halinde ifade edilebilir.

$$\frac{\partial^+ E_p}{\partial \alpha} = \sum_{x^* \in S} \frac{\partial^+ E_p}{\partial x^*} \frac{\partial f^*}{\partial \alpha} \quad (2.13)$$

α parametresini içeren nöron kümesi S ve x^*, f^* bu kümenin çıktı değeri ve fonksiyonudur. α 'ya göre genel hata sinyali E 'nin türevi aşağıdaki gibidir.

$$\frac{\partial^+ E}{\partial \alpha} = \sum_{p=1}^P \frac{\partial^+ E_p}{\partial \alpha} \quad (2.14)$$

α 'nın güncelleme formülü ise şöyledir:

$$\Delta \alpha = -\eta \frac{\partial^+ E}{\partial \alpha} \quad (2.15)$$

Öğrenme oranı η ise

$$\eta = \frac{\kappa}{\sqrt{\sum_{\alpha} \left(\frac{\partial E}{\partial \alpha} \right)^2}} \quad (2.16)$$

biçimindedir.

Burada κ parametre uzayındaki yöntürev yönüyle birlikte her bir geçişin uzunluğu olarak tanımlanabilir. (Jang, Sung ve Mizutani, 2012)

Hata sinyallerinin hesaplanmasında kullanılan başka bir sistematik yol ise hata yayılım ağı ya da duyarlılık modelidir. Bu yöntemin işleyiş ise orijinal uyarlamalı ağdaki bağlantıları tersine çevirip, çıktı tabakasındaki hata sinyallerini girdi değerleri olarak yeni bir ağa uygulama şeklindedir.

Değişik uygulamalarda uyumlu bir şekilde kullanılabilme üzere iki çeşit öğrenme modeli mevcuttur. Çevrimdışı öğrenme (toplu öğrenme), alfa parametresine dayalı olan güncelleme formülü her bir eğitim döngüsü bitişinde güncellenecek şekilde tasarlanmıştır. Diğer yandan çevrimiçi öğrenme (desen desen öğrenme) ise parametrelerin girdi çıktı çiftlerinin elde edilmesinin hemen ardından güncellenmesine dayanır. İki öğrenme modelinin birlikte kullanılması da mümkündür.

2.7.2. Geri beslemeli ağlar için genişletilmiş geri yayılım

Geri beslemeli ağlar için yöntrev vektörlerini bulmak amacıyla kullanılan geri yayılım prosedürünün genişletilmiş halini elde etmek mümkündür.

Yinelenen ağlar için geri yayılım prosedürünü doğru bir şekilde elde etmek için ağı tatmin edecek iki işlemi ayırt etmemiz gerekmektedir. Bunlar eş zamanlı işlem ve devamlılık işlemidir ve geri yayılım prosedürü ile eşleşen bu iki işlem bir sonraki bölümde açıklanacaktır.

2.7.3. Çok tabakalı algılayıcılarda geri yayılım

Tek tabakalı doğrusal algılayıcılar doğrusal ayırıcı fonksiyon içermesi ve sadece tek tabakadan oluşması nedeniyle sınırlı ve yetersiz kalmalarına neden olmuştur. Temel bazı matematiksel fonksiyonların çözümünü bile gerçekleştiremeyen bu algılayıcılar, birden fazla tabaka içerdiklerinde bu sorunların üstesinden gelseler de doğrusal bir ayırıcı olarak kalmaları ve eğitim algoritmalarının olmayışı 1974 yılına kadar ilginin azalmasına ve araştırmaların durmasına neden olmuştur.

Werbos (1974) tarafından geri yayılım algoritmasının bulunmasıyla yeni bir dönem başladıysa da hak ettiği ilgiyi bulamamış ve Rumelhart (1986) tarafından yeniden formüle edilmesiyle geri yayılım algoritması araştırmacıların ilgisini çekmiş ve hızla araştırılmaya, geliştirilmeye başlamıştır.

Tek tabakalı algılayıcılar yapay sinir ağlarının temelini oluşturmalarına karşın anlama, öğrenme ve birçok açıdan türevleri alınamayan sınırlayıcı aktivasyon fonksiyonlarına sahip olmalarından dolayı, çok tabakalı algılayıcıların öğrenme stratejileri devamlı (sürekli) aktivasyon fonksiyonları kullanılmaya başlanana dek işaret ve adım fonksiyonlarıyla açıklanamamıştır.

Çok tabakalı algılayıcılar gelen sinyalleri tabakadaki her nöronun aynı şekilde işlendiği uyarlamalı ağlardır. Nörona gelen girdi ve ağırlıkların genelde toplamlarından oluşan net değeri, türevleri alınabilen doğrusal olmayan aktivasyon fonksiyonlarıyla işlenir.

Çokça kullanılan üç adet aktivasyon fonksiyonları: lojistik, hiperbolik tanjant ve birim fonksiyonlarıdır. Hiperbolik tanjant ve lojistik fonksiyonları, sırasıyla işaret ve adım fonksiyonlarına benzer ve ayrıca pürüzsüz, sıfırdan farklı türevler sağlarlar. Bazen bu fonksiyonlar bastırılmış fonksiyon olarak adlandırılırlar ve veri aralıkları (0,1) ve (-1,1) olarak bastırılır. Aynı zamanda pürüzsüz ve asimptotik özellikler taşıyan “S” şeklinde eğriler oluşturdıkları için sigmoidal fonksiyon olarak da adlandırılırlar.

Bazen hiperbolik tanjant fonksiyonu “çift kutuplu sigmoid”, lojistik fonksiyon ise “tek kutuplu sigmoid” olarak adlandırılır. Bu iki fonksiyon genelde regresyon ve sınıflama problemlerinde kullanılır. Sinir ağlarında değişken değerli fonksiyon yakınsamalarında (0,1) ve (-1,1) aralığında sınırlamak adına bastırılmış fonksiyon kullanılmaz; genelde bu durumda doğrusal nöronlar olarak adlandırılan çıktı tabakasında birim fonksiyon kullanılır.

2.7.3.1. Geri yayılım algoritması

Geri yayılımda, basitleştirmek adına aktivasyon fonksiyonu olarak lojistik fonksiyon kullanılmıştır. Net değeri, $\bar{x}$ nörona gelen sinyallerin ağırlıklı toplam ve yan değerini içerir.

$$\bar{x}_j = \sum_i w_{ij}x_i + w_j \quad (2.17)$$

$$x_j = f(\bar{x}_j) = \frac{1}{1+\exp(-\bar{x}_j)} \quad (2.18)$$

x_i , i . nöronun çıktısı, w_{ij} ise i . ve j . nöronun bağlantısına ilişkin ağırlık değeri ve w_j yan değeridir. Ağırlık değerlerinin değişimi, nöronun davranışını değiştirir ve böylece bütün ağın davranışı değişir.

Geriye Hata Yayılımı ya da daha çok bilinen adıyla Geri Yayılım ya da Genelleştirilmiş Delta Kuralı olarak adlandırılan öğrenme algoritmasını açıklamadan önce ilk olarak p . girdi-çıkı çiftleri için hata ölçütü karesi belirlenir.

$$E_p = \sum_k (d_k - x_k)^2 \quad (2.19)$$

Burada k . nöron için d_k hedef değeri, x_k çıktı değeri olarak tanımlanmıştır. i . Nöron için yontürev vektörünü yani hata terimi $\bar{e}_i$ oluşturulur.

$$\bar{e}_i = \frac{\partial^+ E}{\partial \bar{x}_i} \quad (2.20)$$

Zincir kuralı ile birlikte $\bar{e}_i$ için özyinelemeli formül aşağıdaki gibi yazılabilir.

$$\bar{e}_i = \begin{cases} -2(d_i - x_i) \frac{\partial x_i}{\partial \bar{x}_i} = -2(d_i - x_i)x_i(1 - x_i), & \text{eğer } i. \text{ nöron çıktı nöronu ise} \\ \frac{\partial x_i}{\partial \bar{x}_i} = \sum_{j, i < j} \frac{\partial^+ E}{\partial \bar{x}_j} \frac{\partial \bar{x}_j}{\partial x_i} = x_i(1 - x_i) \sum_{j, i < j} \bar{e}_j w_{ij}, & \text{diğer durumda} \end{cases} \quad (2.21)$$

burada w_{ij} , i . nöron ile j . nöron arasındaki ağırlık değeridir ve eğer bu değer sıfıra eşitse i . nöron ile j . nöron arasında bağlantı yoktur. Sonrasında çevrimiçi öğrenme kuralına göre ağırlık güncellenmesi için şu eşitlik kullanılır;

$$\Delta w_{ki} = -\eta \frac{\partial^+ E_p}{\partial w_{ki}} = -\eta \frac{\partial^+ E_p}{\partial \bar{x}_i} \frac{\partial \bar{x}_i}{\partial w_{ki}} = -\eta \bar{e}_j x_k \quad (2.22)$$

Burada η yakınsama hızını etkileyen ve öğrenme sürecinde ağırlıkların durağanlığını etkileyen öğrenme oranıdır. Yan değeri için güncelleme benzer şekilde elde edilebilmektedir.

Çevrimdışı öğrenme kuralına göre ağırlıklar bütün veri seti gösteriminden sonra ya da bir diğer deyişle her bir iterasyondan sonra elde edilir.

$$\Delta w_{ki} = -\eta \frac{\partial^+ E}{\partial w_{ki}} = -\eta \sum_p \frac{\partial^+ E_p}{\partial w_{ki}} \quad (2.23)$$

$$\Delta w = -\eta \frac{\partial^+ E}{\partial w} = -\eta \nabla_w E \quad (2.24)$$

Vektör formatında da $E = \sum_p E_p$ olarak yazılabilir ve veri seti boyunca gerçek yöntürev doğrultusu bu yolla elde edilir.

2.7.3.2. Eğitimin hızlandırılması için yöntemler

Çok tabakalı algılayıcılarda geri yayılım eğitimi hızlandırmak amacıyla literatürde oldukça fazla yöntem mevcuttur. Bazıları genel olarak bütün geri yayılım dik iniş yöntemine uygulanabilir olsa da, bazıları sadece çok tabakalı algılayıcılarda geri yayılım yönteminde etkilidir.

Çevrimdışı eğitimi hızlandırmanın tek yolu momentum terimidir. Bu terim şu şekilde verilebilir:

$$\Delta w = -\eta \nabla_w E + \alpha \Delta w_{öncül} \quad (2.25)$$

$w_{öncül}$ öncül güncelleme miktarını ve momentum sabiti α genellikle uygulamada 0,1 ile 1 arasında değer alır. Momentum teriminin eklenmesi ağırlık güncellenmesini pürüzsüzleştirmekte ve yöntürev gürültüden veya hata alanındaki yüksek uzaysal frekanslarına bağlı düzensiz ağırlık değişimlerine direnç eğilimi gösterir. Fakat momentum teriminin kullanımı her zaman eğitim hızını artırmaz, daha çok uygulamaya bağlı olarak gözlemlenir.

Diğer kullanışlı bir teknik ise normalleştirilmiş ağırlık güncellenmesidir.

$$\Delta w = -\eta \frac{\nabla_w E}{\|\nabla_w E\|} \quad (2.26)$$

Bu teknikle ağırlık vektörünü, ağırlık uzayında her güncelleme aynı “ η ” Öklid uzaklığında gerçekleştirilir ve bu sayede “ η ” uzaklığı kontrol edilebilir.

Bazen işlenmemiş eğitim setinde veri ölçeklenmesi tercih edilebilir ve bu işlenmiş veri eğitim için kullanılır. Çıktıların ölçeklenmesi ise hedef değerlerinin, sigmoidal aktivasyon fonksiyonunun sınırları içerisinde kalmasını sağlanmaktadır. Örneğin hiperbolik tanjant fonksiyonu kullanılan çok tabakalı algılayıcılarda hedef değerleri olağan aktivasyon fonksiyonu aralığı olan $[-1, 1]$ aralığı yerine $[-0.9, 0.9]$ aralığında olmalıdır. Bu şekilde bazı bağlantı ağırlıklarının sonsuz değerler alması ve eğitimin yavaşlaması önlenabilmektedir. Girdi ölçeklenmesinde ise genellikle girdiler aktivasyon fonksiyonun aralığında ölçeklendirilir. Bu sayede bağlantı ağırlıkları eğitim aşamasında aynı derecede etkiye maruz kalırlar.

YSA'daki başlangıç ağırlık değerleri ve yan değerleri, $[-1, 1]$ aralığında eşit olarak dağılmalıdır. Eğer bu değiştirilebilir parametrelere ait başlangıç değerleri çok büyük seçilirse, bazı nöronlar doymuş hale gelebilir ve küçük hata sinyalleri üretebilirler. Diğer yandan çok küçük seçilirse, yöntürev vektörü küçük olur ve öğrenme çok yavaş gerçekleşir.

2.7.3.3. Çok tabakalı algılayıcıların tahmin gücü

Geri yayımlı çok tabakalı algılayıcıların tahmin gücü bazı araştırmacılar tarafından keşfedilmiştir. Yine de ağırlık boyutunun belirlenmesinde yani gizli tabakadaki nöron sayısının belirlenmesinde çok az teorik rehber bulunmaktadır. Cybenko (1989), bir tane gizli tabakaya ve belirlenmiş sürekli sigmoidal doğrusal olmayan aktivasyon fonksiyonuna sahip olan, geri yayımlı çok tabakalı algılayıcının herhangi bir sürekli fonksiyonu iyi bir şekilde tahmin edebildiğini göstermiştir. Lippmann (1987), aktivasyon fonksiyonu olarak basamak fonksiyonunu kullanan iki gizli tabakaya sahip geri yayımlı çok tabakalı algılayıcıların, karmaşık kararlar oluşturarak bölgeleri, iki farklı sınıfa ayrılması işlemini gelişigüzel gerçekleştirebileceğini göstermiştir.

2.8. Model Seçimi Yöntemleri

Sayısız öngörü uygulamalarında başarıyla kullanılmasına rağmen YSA ile model oluşturma konusunda çözilemeyen bazı problemler söz konusudur. Bunlardan en kritik olanlarından bir tanesi ise en uygun ağ mimarisinin nasıl seçilmesi gerektiğidir Aladag v.d. (2010).

Model seçimi geleneksel doğrusal öngörü uygulamalarına nazaran YSA gibi doğrusal olmayan modeller için daha da önemli bir konudur. Doğal olarak oldukça fazla sayıda parametrenin belirlenmesi gerektiğinden YSA çoğu zaman aşırı uyum sorunu ile boğuşur. Bu eğitim kümesinde çok iyi uyum sağlaması fakat test kümesinde çok kötü öngörü değerleri elde etmesi anlamına gelebilmektedir.

Bu etkiyi düzeltmek için bir önceki bölümde kısaca bahsedildiği üzere YSA literatüründe iki tip model seçme yaklaşımı kullanılır. Birincisi, çapraz doğrulama temelli yaklaşım ile veriyi eğitim, geçerlilik ve test kümesi olarak üç parçaya bölmektir. İkinci yaklaşım ise geleneksel zaman serisi literatüründen alınan örneklem içi model seçme kriterlerinin kullanılmasıdır.

2.8.1. Örneklem içi model seçimi

Bu yaklaşım, alternatif modeller arasından örneklem içi kriter kullanarak en iyi öngörü modelinin seçilmesine yardımcı olması umularak, uygun hesaplanabilir kısa yol olarak sadece belirli bir örneklem içi kritere dayanır. Büyük modelleri cezalandıran ve örneklem içi model seçme kriterlerinden sıkça kullanılan bilgi tabanlı kriterlerden olan ABÖ ve BBÖ genellikle aşırı uyum eğilimindedirler. Örneğin Franses ve Draisma (1997) BBÖ' nü gizli tabakanın değişken mevsimsellik desenini ayırt etmesi için nöron sayısını belirleme amacıyla tasarlamışlardır.

2.8.2. Örneklem dışı model seçimi

Eğitim ve geçerlilik kümeleri YSA tarafından model oluşturmak için kullanılırken test kümesi örneklem dışı değerlendirmeler için ayrılır. Eğitim seti alternatif YSA modelleri için parametre tahmini yapmak üzere kullanılır. Öğrenen ağ geçerlilik kümesinde değerlendirilir. Geçerlilik kümesinde en iyi değerlere sahip olan model nihai öngörü modeli olarak seçilir. Modelin yararlılık ve kullanışlılığı ise test kümesinde değerlendirilir. Örneklem dışı model seçme ve test işlemi aşırı uyum sorununa karşı genellikle oldukça etkilidir.

Fakat bu yaklaşım bazı sınırlamaları vardır. İlk olarak verinin parçalanması tahminlerin değişkenliğini artırmaktadır. Çalışmalar verinin farklı parçalanmasından oluşan değişkenliğin, başlangıç parametresi ve gizli tabadaki nöron sayısının seçimi gibi farklı ağ koşullarından oluşacak değişkenlikten önemli derecede daha fazla olduğunu göstermiştir. Ek olarak verinin bölünmesiyle ilgili genel bir kural mevcut değildir. Sonuç olarak verinin bölünmesi oldukça büyük örneklem büyüklüğü gerektirmektedir. Küçük veri kümeleri ile yapılacak olan uygulamalar modelin güvenilirliğini zayıflatacaktır.



3. PERFORMANS ÖLÇÜTLERİ

3.1. Giriş

Yapay sinir ağlarında deneme yanılma yoluyla en iyi modelin seçilmesi işlemi performans ölçütleri kullanılarak gerçekleştirilmektedir. Temel olarak performans ölçütünün analiz sonucunda işaret ettiği en küçük hata değerine sahip olan mimari en iyi ya da en uygun mimari olmaktadır.

Seçim işleminin gerçekleştirilmesi için kullanılan birçok ölçüt bulunmaktadır. Bu çalışmada bu ölçütler; Mutlak Hatalar, Orantılı Hatalar, Simetrik Hatalar, Göreceli Hatalar, Ölçekli Hatalar ve Diğer Hatalara dayalı olmak üzere 6 ana başlık altında incelenmiştir.

3.2. Mutlak Hatalara Dayalı Ölçütler

Mutlak hataya dayalı performans ölçütleri

$$e_t = (y_t - \hat{y}_t) \quad (3.1)$$

hatasını temel almaktadır. Burada, t zamanındaki gözlem değeri y_t ve tahmin değeri ise $\hat{y}_t$ ile gösterilmektedir. Eşitlik (3.1)'e dayalı performans ölçütleri aşağıda verilmektedir.

$$\text{Ortalama Mutlak Hata (OMH)} = \text{ortalama}_{i=1,n} |e_i| \quad (3.2)$$

$$\text{Medyan Mutlak Hata (MMH)} = \text{medyan}_{i=1,n} |e_i| \quad (3.3)$$

$$\text{Geometrik Ortalama Mutlak Hata (GOMH)} = \text{gortalama}_{i=1,n} |e_i| \quad (3.4)$$

$$\text{Hata Kare Ortalama (HKO)} = \text{ortalama}_{i=1,n} (e_i^2) \quad (3.5)$$

$$\text{Hata Kare Ortalama Karekökü (HKOK)} = \sqrt{\text{ortalama}_{i=1,n} (e_i^2)} \quad (3.6)$$

$$\text{Dördüncü Dereceden Hata Ortalama (DDHO)} = \sqrt[4]{\text{ortalama}_{i=1,n}(e_i^4)} \quad (3.7)$$

Mutlak hataların en büyük dezavantajı, ölçekten bağımsız olmalarıdır. Farklı ölçeklendirilmiş gözlemler aynı öngörü için karışıklığa neden olabilir ve sonuçları uygun olmayabilir. Ayrıca bu durum farklı çalışmalar ya da yöntemler arasındaki karşılaştırmayı imkânsız kılabilir. Bunun üstesinden gelmek için araştırmacılar modelleme öncesinde veriyi ölçeklendirmelidirler.

3.3. Orantılı Hatalara Dayalı Ölçütler

Orantılı hataya dayalı performans ölçütleri

$$p_t = \frac{(y_t - \hat{y}_t)}{y_t} \quad (3.8)$$

hatasını temel almaktadır. Burada, t zamanındaki gözlem değeri y_t ve tahmin değeri ise $\hat{y}_t$ ile gösterilmektedir. Eşitlik (3.8)'e dayalı performans ölçütleri aşağıda verilmektedir.

$$\text{Ortalama Mutlak Orantılı Hata (OMOH)} = \text{ortalama}_{i=1,n}|p_i| \quad (3.9)$$

$$\text{Medyan Mutlak Orantılı Hata (MMOH)} = \text{medyan}_{i=1,n}|p_i| \quad (3.10)$$

$$\text{Hata Kare Ortalama Orantılı Karekökü (HKOOK)} = \sqrt{\text{ortalama}_{i=1,n}(p_i^2)} \quad (3.11)$$

$$\text{Hata Kare Medyan Orantılı Karekökü (HKMOK)} = \sqrt{\text{medyan}_{i=1,n}(p_i^2)} \quad (3.12)$$

Orantılı hataların en büyük dezavantajı gözlem değerinin sıfıra eşit olmasıyla birlikte ortaya çıkabilecek sıfıra bölünme sorunudur. Bunun üstesinden gelmek için bazı düzenlemeler yapmak gereklidir. Diğer bir önemli dezavantaj ise orantılı hataların simetrik olmamasıdır. Bu, sonuçların tahmin değerlerinin gözlem değerlerinden büyük ya da küçük olmasına göre değişebileceği anlamına gelmektedir.

3.4. Simetrik Hatalara Dayalı Ölçütler

Simetrik hataya dayalı performans ölçütleri

$$s_t = \frac{|y_t - \hat{y}_t|}{(y_t + \hat{y}_t)} \quad (3.13)$$

hatasını temel almaktadır. Burada, t zamanındaki gözlem değeri y_t ve tahmin değeri ise $\hat{y}_t$ ile gösterilmektedir. Eşitlik (3.13)'e dayalı performans ölçütleri aşağıda verilmektedir.

$$\text{Simetrik Ortalama Mutlak Orantılı Hata (SOMOH)} = \text{ortalama}_{i=1,n}(s_i) \quad (3.14)$$

$$\text{Simetrik Medyan Mutlak Orantılı Hata (SMMOH)} = \text{medyan}_{i=1,n}(s_i) \quad (3.15)$$

Koehler (2001) çalışmasında bu ölçütlerin simetrik olarak adlandırılmasına rağmen aslında simetrik olmadıkları ifade edilmektedir. Orantılı hatalara benzer olarak, gözlem değerinin sıfıra eşit olmasıyla birlikte nadiren ortaya çıkabilecek sıfıra bölünme sorunu burada da geçerlidir.

3.5. Göreceli Hatalara Dayalı Ölçütler

Göreceli hataya dayalı performans ölçütleri

$$r_t = \frac{|y_t - \hat{y}_t|}{(y_t - f_t^*)} \quad (3.16)$$

$$f_t^* = y_{t-l} \quad (3.17)$$

hatasını temel almaktadır. Burada, t zamanındaki gözlem değeri y_t ve tahmin değeri ise $\hat{y}_t$ ile gösterilmektedir. f_t^* referans model değeri ya da tahmin değeri olarak adlandırılmaktadır. Referans modelinin genel kullanımı verinin t zamanında ve l gecikmedeki değeridir. Bu çalışmada referans modeli olarak bir gecikmeli seri gözlemleri $f_t^* = y_{t-1}$ kullanılmıştır. Eşitlik (3.16 ve 3.17)'ye dayalı performans ölçütleri aşağıda verilmektedir.

$$\text{Ortalama Mutlak Göreceli Hata (OMGH)} = \text{ortalama}_{i=1,n} |r_i| \quad (3.18)$$

$$\text{Medyan Mutlak Göreceli Hata (MMGH)} = \text{medyan}_{i=1,n} |r_i| \quad (3.19)$$

$$\text{Geometrik Ortalama Mutlak Göreceli Hata (GOMGH)} = \text{gortalama}_{i=1,n} |r_i| \quad (3.20)$$

Göreceli hataların en büyük dezavantajı gözlem değerinin referans modeline eşit olduğu zamanlarda ortaya çıkabilecek sifıra bölünme sorunudur.

3.6. Ölçekli Hatalara Dayalı Ölçütler

Ölçekli hataya dayalı performans ölçütleri

$$sc_t = \frac{|y_t - \hat{y}_t|}{\frac{1}{n-1} \sum_{t=2}^n |y_t - y_{t-1}|} \quad (3.21)$$

hatasını temel almaktadır. Burada, $t, t-1$ zamanındaki gözlem değeri y_t, y_{t-1} ve tahmin değeri ise $\hat{y}_t$ ile gösterilmektedir. Eşitlik (3.21)'e dayalı performans ölçütleri aşağıda verilmektedir.

$$\text{Ortalama Mutlak Ölçekli Hata (OMÖH)} = \text{ortalama}_{i=1,n} |sc_i| \quad (3.22)$$

$$\text{Hata Kare Ortalama Ölçekli Karekökü (HKOÖK)} = \sqrt{\text{ortalama}_{i=1,n} (sc_i^2)} \quad (3.23)$$

3.7. Ağırlıklara Dayalı Ölçütler

Ağırlıklı hatalara dayalı ölçütler, diğer performanslar ölçütlerinin birarada kullanılmasıyla oluşturulan ölçütlerdir. Kullanıcının tercihinine göre seçilen performans ölçütleri, belirli strateji ya da tercihlere dayalı oluşturulan katsayılarla (a_i) çarpılıp toplanarak ağırlıklı hatalar oluşturulur. Burada dikkat edilmesi gereken nokta, katsayılar toplamının 1'e eşit olması $\sum a_i = 1$ gerektiridir.

Eğrioğlu v.d. (2008) tarafından zaman serisi öngörüsünde kullanılması için geliştirilen ağırlıklı bilgi kriteri aşağıdaki gibi verilmektedir.

$$\text{Ağırlıklı Bilgi Kriteri (ABK)} = 0,1 * (AB\ddot{O} + BB\ddot{O}) + 0,2 * (HKOK + OMOH + (1 - YD) + DYD) \quad (3.34)$$

ABÖ, BBÖ, HKOK, OMOH, YD ve DYD ölçütlerinden oluşturulmuş ve sabit katsayılara sahip bir ağırlıklı bilgi kriteridir. ABÖ ve BBÖ katsayıları daha az öneme sahip oldukları düşüncesiyle 0.1 olarak belirlenmiştir. Diğer kriterler ise daha fazla öneme sahip oldukları düşünülerek katsayıları 0.2 olarak belirlenmiştir.

Aladag v.d. (2010) ABK'ni geliştirerek UABK'ni elde etmişlerdir.

$$\text{Uyarlamalı Ağırlıklı Bilgi Kriteri (UABK)} = a_1 * HKOK + a_2 * OMOH + a_3 * (1 - YD) + a_4 * DYD + 0,1 * (AB\ddot{O} + BB\ddot{O}) \quad (3.35)$$

UABK, optimizasyon süreci ile ağırlıkların veriye özgü bir biçimde belirlendiği ve aynı zamanda sabit bazı ağırlık katsayılarına da sahip olabilen bilgi kriteridir. Her bir ölçütün sahip olduğu katsayı kullanıcının belirlediği bir yaklaşımla amaç fonksiyonu doğrultusunda hesaplanır. Aladag v.d. (2010) tarafından kullanılan strateji ise test kümesini 2 parça halinde oluşturarak bu iki test kümesi arasındaki korelasyonu maksimize eden katsayılara sahip UABK'yi hesaplamaktır.

Bal v.d. (2016) tarafından diğer bir ağırlıklı performans kriteri aşağıdaki gibi verilmektedir.

$$\text{Genişletilmiş Ağırlıklı Performans Kriteri GAPK} = \frac{1}{19} * (HKO + HKOK + DDHO + OMOH + OMH + GOMH + MMH + MMOH + NS + OMGH + MMGH + GOMGH + HKOGK + HKM\ddot{O}K + SOMOH + SMMOH + MSMMOH + OM\ddot{O}H + HKO\ddot{O}K) \quad (3.36)$$

GAPK, 19 farklı hatadan meydana gelen ve herbirinin özelliklerini taşıyan, sabit katsayılara sahip performans kriteridir. Görüldüğü üzere GAPK kriteri, cezalandırma temeline dayanan örneklem içi bilgi kriterleri olan ABÖ ve BBÖ'yi içermemektedir. Cezalandırma terimine sahip olmalarından kaynaklanan dezavantajları bu kriterlerin alternatif sınır ağı mimarilerini görmezden gelmelerine neden olmaktadır. (Bal, Demir ve Aladag, 2016)

3.8. Diğer Ölçütler

Bu kısımdaki eşitliklerde kullanılan N , y_t , $\hat{y}_t$ ve m simgeleri sırasıyla veri seti büyüklüğünü, gözlem değerini, tahmin değerini ve sınır ağındaki ağırlık sayısını göstermektedir.

İlk olarak, sıkça kullanılan Akaike Bilgi Ölçütünden bahsedilecektir.

$$\text{Akaike Bilgi Ölçütü (ABÖ)} = \log \left(\frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{N} \right) + \frac{2*m}{N} \quad (3.24)$$

Eşitlik (3.24)'ün ilk terimi artıkların varyansının maksimum olabilirlik tahminini içerir.

Dolayısıyla ilk terim modelin veriyle olan uyum iyiliğini, ikinci terim ise modelin aşırı uyum sorunuyla karşılaşmaması için cezalandırma işlemini gerçekleştirir. Optimal model, ABÖ değeri minimuma ulaştığında elde edilir. Görüleceği üzere model karmaşıklaştıkça ilk terim küçülecek fakat ikinci terim büyüyecektir. Dolayısıyla teorik olarak, ABÖ dengeli model uyumu ve modelin cimrilikliğini içeren makul bir kriterdir.

Ancak ABÖ'nün verinin normal dağılımdan türetildiği varsayımını temel aldığını belirtmek gerekir. Gerçek-yaşam zaman serilerinin sadece az bir kısmının normallik gösterdiğini düşünürsek, bu durum için aslında ABÖ optimal bir ölçüt değildir. Hatta ABÖ kriterinin model seçimi açısından tutarlı bir ölçüt olmadığı da söylenebilir.

İkinci olarak ABÖ'nün farklılaştırılmasıyla oluşturulan Bayesci Bilgi Ölçütünden bahsedilecektir.

$$\text{Bayesci Bilgi Ölçütü (BBÖ)} = \log \left(\frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{N} \right) + \frac{m*\log(N)}{N} \quad (3.25)$$

Bir diğer popüler ölçüt olan BBÖ ise ABÖ'ye çok benzerdir. Farklı olan cezalandırma ifadesi gözlem sayısının 7'nin üzerinde olduğu durumlarda karmaşık modelleri ABÖ'den daha fazla cezalandırmaktadır. BBÖ'nün Otoregresif (AR) modelleri için tutarlı bir ölçüt olduğu Rissanen (1980) tarafından gösterilmiştir. Gerçek yaşam uygulamalarında, BBÖ kriteri ABÖ kriterine göre daha güvenilir sonuçlar verdiği için tercih edilmektedir.

Literatürde, cezalandırma teriminin parametre sayısını içermesinin uygunluğu tartışılmaktadır. Genellikle birden büyük değerler alan m sabiti cezalandırma teriminin esnekliği açısından ölçütü daha uygun hale getirmiştir, fakat literatürde doğrusal olmayan model seçimi için uygun m değerinin seçimiyle ilgili bir araştırma yapılmamıştır.

$$\text{Nash-Sutcliffe Etkinlik Katsayısı (NS)} = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (3.26)$$

Nash-Sutcliffe (1970) tarafından geliştirilen etkinlik katsayısı, gözlemler ve tahminler arasındaki hata ile gözlemlerin değişim ölçütünün birbirine oranlanmasıyla elde edilen bir performans ölçütüdür. NS katsayısı sıfıra yaklaştıkça performans artar.

Görüldüğü üzere bütün performans kriterleri bazı avantaj ve dezavantajlara sahiptir. Farklı açılardan bakıldığında *ortalama* operatörü kullanan her ölçütün dezavantajı, uç değerlerden oldukça etkilenmeleridir.

Ayrıca medyan operatörü kullanan her ölçütün dezavantajı ise veri seti büyüdükçe hesaplamaların artmasıdır. ABÖ ve BBÖ ölçütleri büyük modelleri cezalandırdıkları için ve YSA'nın tabaka sayısı, nöron sayısı, öğrenme algoritması, aktivasyon fonksiyonu vb. gibi belirlenmesi gereken birçok parametreye sahip olması nedeniyle değerlendirmeyi fazla cezalandırma ile sonuçlandırabilirler.

$$\text{Yön Doğruluğu (YD)} = \frac{1}{N} \sum_{t=1}^N a_t, \quad a_t = \begin{cases} 1 & \text{eğer } (y_{t+1} - y_t)(\hat{y}_{t+1} - y_t) > 0, \\ 0 & \text{diğer durumlarda,} \end{cases} \quad (3.27)$$

YD, tahmin ile gözlem değerlerinin aynı doğrultuda olup olmadığını ölçen bir performans ölçütüdür. t ile $t + 1$ zamanında gözlem değeriyle aynı doğrultuda artan ya da azalan tahmin değerleri için 1, farklı doğrultuda elde edilen değerler içinde 0 değerini alır ve bu değerlerin ortalamalarından oluşur. YD ölçütü bire yaklaştıkça aynı derecede iyi tahmin değerleri elde edilir.

$$\text{Değiştirilmiş Yön Doğruluğu (DYD)} = \frac{\sum_{t=1}^{N-1} D_t}{N-1} \quad (3.28)$$

Eşitlik (3.28)'de kullanılan D_t aşağıdaki eşitlikler yardımıyla hesaplanmaktadır.

$$D_t = (A_t - F_t)^2, \quad (3.29)$$

$$A_t = 1, \quad y_{t+1} - y_t \leq 0, \quad (3.30)$$

$$A_t = 0, \quad y_{t+1} - y_t > 0, \quad (3.31)$$

$$F_t = 1, \quad \check{y}_{t+1} - \check{y}_t \leq 0, \quad (3.32)$$

$$F_t = 0, \quad \check{y}_{t+1} - \check{y}_t > 0, \quad (3.33)$$


DYD, YD kriterinden esinlenilip oluşturulmuş bir ölçüttür. DYD kriteri yön doğruluğunu daha hassas bir şekilde ölçmektedir. (Eğrioğlu v.d., 2008)




4. GERÇEK VE YAPAY VERİLER İLE PERFORMANS ÖLÇÜTLERİNİN KARŞILAŞTIRILMASI

Bu çalışmada ele alınan ölçütlerin uygulama performanslarını değerlendirmek üzere Dolar(USD)/Avro(EUR), Dolar(USD)/İngiliz Sterlini(GBP), Dolar(USD)/Japon Yeni(JPY) döviz kurlarını içeren 3 zaman serisi ve yapay olarak elde edilen Doğrusal Olmayan Otoregresif, Mevsimsel Otoregresif, Sinüs, Üstel olmak üzere 4 farklı zaman serisi verileri kullanılmıştır. Ayrıca yıllar boyunca bir çok çalışmada kullanılan Yellowstone parkındaki gayzerlerin dakika bazında patlama süreleri (Hardle, 1991), 1821-1934 yılları arasında yakalanan yıllık Kanada vaşağı sayısı (Bulmer, 1974) ve 1949-1960 yılları arasında elde edilen aylık uçak yolcu sayısı (Box v.d., 1976) olmak üzere bilindik 3 zaman serisi verileri de uygulama için kullanılmıştır.

Döviz kurlarına ilişkin veriler Türkiye Cumhuriyeti Merkez Bankası resmi internet sitesinden (www.tcmb.gov.tr) alınmıştır. Elde edilen döviz kurlarına ilişkin zaman serisi verileri; 23 Mart 2012 ile 9 Aralık 2016 tarihleri arasında toplam 247 gözlemde oluşan haftalık verilerden oluşmaktadır. Haftalık gözlem değerleri, haftanın her iş günü için günlük parite değerlerinin ortalamasından oluşmaktadır. Simülasyonla elde edilen yapay zaman serisi verilerinin her biri toplamda 256 veri noktasından oluşmaktadır. Kanada vaşağı, Yellowstone gayzer patlama süreleri ve uçak yolcu sayısı ile ilgili seriler ise sırasıyla 114,272 ve 144 gözlem sayısına eşittir. Şekil 4.1, 4.2, 4.3, 4.4, 4.5, 4.6, 4.7, 4.8, 4.9 ve 4.10'da döviz kurları ve simülasyon verilerinin çizgi grafikleri verilmektedir. Grafiklerden görüldüğü üzere, zaman serilerinin oldukça karmaşık yapılara ve farklı karakteristiklere sahip oldukları söylenebilir.




Şekil 4.1 Dolar(USD)/Avro(EUR) döviz kuru grafiği




Şekil 4.2. Dolar(USD)/İngiliz Sterlini(GBP) döviz kuru grafiği




Şekil 4.3. Dolar(USD)/Japon Yeni(JPY) döviz kuru grafiği




Şekil 4.4. Doğrusal Olmayan Otoregresif veri grafiği




Şekil 4.5. Mevsimsel Otoregresif veri grafiği




Şekil 4.6. Sinüs veri grafiği



Şekil 4.7. Üstel veri grafiği



Şekil 4.8. Yellowstone gayzer patlama süreleri veri grafiği



Şekil 4.9. Kanada vaşığı veri grafiği



Şekil 4.10. Uçak Yolcu Sayısı veri grafiği

4.1. Modelleme

YSA literatüründe, aşırı uyum sorununun üstesinden gelmek için iki tane model seçimi yaklaşımı bulunmaktadır. İlki ve uygulamada sıkça kullanılan yaklaşım, veri setinin parçalara bölünmesi biçimindedir. Genellikle veri seti, eğitim ve test kümesi olmak

üzere 2 parçaya ayrılır. Eğitim kümesi YSA geliştirme sürecinde, test kümesi ise performans değerlendirme sürecinde kullanılır (Günay v.d., 2007).

İkincisi ise klasik bir yaklaşım olan eğitim sürecinde en iyi modelin belirlenmesi yaklaşımıdır. Akaike Bilgi Ölçütü ve Bayesci Bilgi Ölçütü gibi bilgi kriterleri tarafından en iyi öğrenen modelin seçilmesi işleminin dezavantajları ise kısaca alternatif modellerin gözardı edilmesi ve seçilen modelin performansının ölçülememesi durumudur.

Bu çalışmada ise geçerlilik kümesi kullanılmamış, veri seti eğitim ve test olmak üzere iki parçaya ayrılmıştır. Döviz kurları için ilk 210 gözlem eğitim (%85) son 37 gözlem test (%15); simülasyon verileri için ilk 218 gözlem eğitim (%85) son 38 gözlem test kümesi (%15); Yellowstone gayzer patlama süreleri için 231 gözlem eğitim (%85) son 41 gözlem test (%15); Kanada vaşağı için 97 gözlem eğitim (%85) son 17 gözlem test (%15) ve uçak yolcu sayısı için 122 gözlem eğitim (%85) son 22 gözlem test (%15), olarak kullanılmıştır.

Modelleme aşamasında, bir çok farklı model bir çok defa tekrarlanarak en iyi modelin seçilmesi işlemi gerçekleştirilmiştir. Çıktı tabakasında tek bir nöronun bulunduğu mimariye sahip olan YSA tasarımı girdi ve gizli tabakasındaki nöronların sayısı model sayısını belirleyen parametreleri oluşturmaktadır. Her iki tabaka için sırasıyla 1 ile 12 arasında değişen sayıda nöron içeren ve dolayısıyla toplamda 144 farklı mimari her bir modelleme tekrarı için incelenmiş ve en iyi model seçimi işlemi gerçekleştirilmiştir. Çalışmada her veri seti için 1000 modelleme tekrarı yeterli görülmüştür. Böylece 1000 adet en iyi mimari karşılaştırma için elde edilmiştir.

4.1.1. Verinin tasarımı ve ön işleme

Bu bölümde, modellenen verinin YSA'daki çalışma prensibi, verinin nasıl iletileceği ve ön işleme anlatılmaktadır.

Öncelikle öngörü işlemi için sinir ağlarının zaman serileri ile çalışma prensibinden bahsedilecektir. Girdi tabakasındaki her bir nöron zaman serisinin gecikmeli değerlerinden oluşan serileri içermektedir. Girdi tabakasındaki nöron sayısı sinir

ağında kullanılacak serilerin gecikme sayısına eşit olup çıktı tabakasında bulunan tek nörona karşılık gelmesi için ise serinin kendisi hedef değerleri olarak belirlenmektedir.

Çizelge 4.1. Yapay Sinir Ağları' nın çalışma prensibi

Girdi Değerleri		Hedef Değerleri
X_{t-2}	X_{t-1}	X_t
0,746	0,857	0,565
0,857	0,565	0,911
0,565	0,911	0,256
0,911	0,256	0,137
0,256	0,137	0,285
0,137	0,285	0,917
0,285	0,917	0,257
0,917	0,257	0,105
0,257	0,105	0,525
0,105	0,525	0,363

Çizelge 4.1.'de görüldüğü üzere 12 değerden oluşan zaman serisinin birinci ve ikinci gecikmeli serisi girdi değerleri olarak girdi tabakasındaki iki nörona denk gelmektedir. Çıktı tabakasındaki nörona denk gelen gecikmeye sahip olmayan seri ise hedef değerlerini oluşturmaktadır. İki girdiye sahip olan bu örnek sinir ağında serinin ilk iki değerine karşılık üçüncü değer hedef değeri olmaktadır ve aynı prensiple zaman serisindeki son gözlem değerine ulaşana kadar eğitim işlemi devam eder. (Günay v.d., 2007)

Verinin kullanılacak aktivasyon fonksiyonuna göre daha uygun aralıklara dönüştürülmesi ya da belirli bir tartıya getirilmesi işlemi verinin ön işleme olarak

adlandırılmaktadır. Ayrıca bu işlem hesaplamaları kolaylaştırmakta ve performans karşılaştırmaları için bir standart oluşturulması açısından önemli bir işlemdir.

Eğer kullanılacak aktivasyon fonksiyonu çift kutuplu ise x_i girdi değerleri;

$$x_i' = \frac{2x_i - (Maks(x_i) + Min(x_i))}{Maks(x_i) - Min(x_i)} \quad (4.1)$$

şeklinde $[-1,1]$ aralığına getirilebilir.

Eğer kullanılacak aktivasyon fonksiyonu tek kutuplu ise x_i girdi değerleri;

$$x_i' = \frac{x_i - Min(x_i)}{Maks(x_i) - Min(x_i)} \quad (4.2)$$

şeklinde girdi değerleri $[0,1]$ aralığına dönüştürülebilir.

Veri seti gerekli dönüşümler gerçekleştirildikten sonra eğitim aşamasına hazır hale gelmektedir. Kullanılacak sinir ağı mimarisinin ve parametlerinin dizaynı ile birlikte modelleme işlemine geçilebilir.

4.1.2. Yapay sinir ağları tasarımı ve kodlama

Sinir ağlarının önemli bir bileşeni olan mimari, kullanılacak amaca göre tasarlanmaktadır. Öngörü için tasarlanan sinir ağlarında, yapılan bir çok çalışma sonucunda tek bir gizli tabakaya sahip olan ve çıktı tabakasında sadece bir tane nöron bulunduran sinir ağının bu işlemi gerçekleştirmek için oldukça yeterli olduğu görülmüştür (Cybenko, 1989).

Modelleme aşaması MATLAB adlı yazılımda gerekli kodlamalar yapıldıktan sonra gerçekleştirilmiştir. Oluşturulan kodlar temel olarak 3 aşamada incelenmiştir. İlk aşamada veri setinden sinir ağında kullanılacak girdi ve hedef değerlerini içeren gecikme matrisleri elde edilmektedir. İkinci aşamada ise sinir ağı oluşturulup

eğitildikten sonra her model için performans ölçütlerinin değerleri hesaplanmıştır. Son aşamada ise oluşturulan 1000 en iyi modelin her bir performans ölçütüne ilişkin değerleri, bir adım ötesi öngörü değeri, test kümesine ilişkin korelasyon değerleri, sinir ağına ilişkin ağırlık değerleri, test kümeleri tek bir dizinde oluşturulmuştur.

Eğitim aşamasında Levenberg-Marquardt geri yayılım algoritması kullanılmıştır. Literatürde bir çok uygulamada kullanılan bu algoritma oldukça hızlı yakınsama hızına sahip kullanımı kolay bir algoritmadır. Aktivasyon fonksiyonu olarak gizli tabakada tanjant sigmoidal fonksiyon kullanılmıştır. Çıktı tabakasında ise sonuçları belirli bir aralıkta sıkıştırmamak için literatürdeki uygulamaların çoğunda da kullanılan birim fonksiyonu kullanılmıştır.

Bu çalışmada girdi ve gizli tabakada 1 ile 12 arasında değişen nöron sayısı yeterli görülmüştür. Her bir modelleme tekrarı için 144 model oluşturulmuş ve en düşük hata değerine yani en yüksek performansa sahip model her bir performans ölçütü için seçilmiştir. Modelleme çalışmasına ilişkin değerler ve istatistikler elde edilmiştir.

4.2. Uygulama Sonuçları

Döviz kuru verileri Dolar(USD)/Avro(EUR), Dolar(USD)/İngiliz Sterlini(GBP), Dolar(USD)/Japon Yeni(JPY); yapay olarak elde edilmiş Doğrusal Olmayan Otoregresif, Mevsimsel Otoregresif, Sinüs, Üstel veri setleri ve Yellowstone gayzer patlama süreleri, Kanada vaşağı ve uçak yolcu sayısı verileri için elde edilen sonuçlar bu kısımda ayrıntılı olarak sunulmaktadır.

4.2.1 Döviz kurlarına ilişkin sonuçlar

Bu kısımda Dolar(USD)/Avro(EUR), Dolar(USD)/İngiliz Sterlini(GBP) ve Dolar(USD)/Japon Yeni(JPY) verilerine ilişkin sonuçlar verilmektedir.

Çizelge 4.2. AVRO döviz kuruna ilişkin sonuçlar


	DOLAR/AVRO				
	Test Kümesi ve Tahminleri Arasındaki Korelasyon Değerlerinin Ortalaması	Test Kümesi ve Tahminleri Arasındaki Mutlak Hataların Ortalaması	Bir Adım Ötesi Öngörülerin Ortalaması, Gerçek Değer=1.071	Bir Adım Ötesi Gerçek Değere Göreceli Yakınlık Yüzdesi	En Çok Sayıda Seçilen Mimari ve Seçilme Sayısı
GAPK	0.98267	0.00316	1.06869	99.78394%	12 - 1 - 1 / 505
ABK	0.99341	0.00369	1.07274	99.83715%	2 - 1 - 1 / 1000
HKOK	0.98208	0.00317	1.06843	99.76040%	12 - 1 - 1 / 581
MMOH	0.91923	0.01674	0.97470	91.00798%	1 - 8 - 1 / 158
OMOH	0.98276	0.00315	1.06958	99.86774%	12 - 1 - 1 / 390
HKOÖK	0.98206	0.00317	1.06840	99.75751%	12 - 1 - 1 / 583
SOMOH	0.98280	0.00315	1.06964	99.87279%	12 - 1 - 1 / 399
OMGH	0.98259	0.00315	1.06955	99.86472%	12 - 1 - 1 / 347
OMÖH	0.98259	0.00315	1.06955	99.86484%	12 - 1 - 1 / 344
NS	0.98208	0.00317	1.06843	99.76040%	12 - 1 - 1 / 581

Çizelge 4.2.'de AVRO döviz kurlarına ilişkin en iyi uyumu en yüksek ortalama korelasyonla ABK ölçütünün gösterdiği görülmektedir. Fakat AVRO için ABK ölçütünün 1000 tekrardaki ortalama mutlak hata değeri MMOH ölçütü ile birlikte diğer ölçütlerden daha yüksek çıktığı dolayısıyla daha düşük performansa sahip oldukları söylenebilmektedir. Öngörü performansları açısından, bir adım ötesi gerçek değere (1.071) en yakın ortalama öngörü 99.87279% ile SOMOH, en uzak ortalama öngörü ise 91.00798% ile MMOH ölçütünün sahip olduğu görülmektedir. Bir çok ölçüt tarafından en çok sayıda seçilen mimarinin AVRO için 12-1-1 mimarisi olduğu söylenebilir.


Çizelge 4.3. AVRO döviz kuruna ilişkin performans ölçütlerinin hata değerleri sonuçları

	DOLAR/AVRO						
	En Küçük Hata Değeri	En Küçük Hata Değerine İlişkin Mimari	En Büyük Hata Değeri	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Ortalaması ve Ortancası		0 - 1 Aralığına Getirilmiş Hata Değerlerinin Standart Sapması	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Değişim Katsayısı
GAPK	0.037711159	6 - 3 - 1	0.053109642	0.810174305	0.998777564	0.280221793	34.58784012
ABK	-2.112433388	2 - 1 - 1	-2.112215423	0.46688514	0.48683033	0.077326678	16.56224877
HKOK	0.002900226	6 - 3 - 1	0.004100494	0.846588977	0.999067498	0.238310285	28.14946707
MMOH	0.001202319	2 - 3 - 1	0.002927782	0.670146135	0.701861653	0.141474073	21.11092868
OMOH	0.002151238	6 - 2 - 1	0.003024893	0.776599937	0.956871709	0.306822335	39.50841618
HKOÖK	0.002616997	6 - 3 - 1	0.003674967	0.855775664	0.999070634	0.228282434	26.67549965
SOMOH	0.002151045	6 - 2 - 1	0.003028037	0.775603625	0.955489406	0.306911373	39.57064707
OMGH	0.002391307	6 - 2 - 1	0.003373972	0.776198585	0.945513364	0.306916863	39.54102324
OMÖH	0.291857354	6 - 2 - 1	0.412622775	0.772515571	0.941267228	0.306175503	39.63357044
NS	0.023029466	6 - 3 - 1	0.046035461	0.834048998	0.99890777	0.251764536	30.18582076

Çizelge 4.3. 'te AVRO için tüm performans ölçütlerine ilişkin 1000 tekrar arasından en küçük hata değerleri, en küçük hata değerlerine ilişkin mimariler ve en büyük hata değeriyle birlikte hatalara ilişkin değişim katsayıları verilmektedir. ABK ve MMOH ölçütleri dışında 6-2-1 ve 6-3-1 mimarileri 1000 tekrar arasında en küçük hataya sahip mimariler olarak seçilmiştir. Hata değerlerinin 0-1 aralığına dönüştürülmesinden sonra hesaplanan değişim katsayılarına bakıldığında ABK ölçütünün en düşük değişime sahip olduğu görülmektedir.



Şekil 4.11. AVRO döviz kuru için 1000 tekrara ait performans ölçütlerinin grafikleri



Şekil 4.11. (devamı)

Şekil 4.11.'de AVRO döviz kurunun tüm performans ölçütlerine ilişkin 1000 tekrar için elde edilen ve 0-1 aralığına getirilen en küçük hata değerleri grafikleri verilmektedir. ABK ve MMOH ölçütlerinin diğer ölçütlere göre daha farklı karakteristiklere sahip oldukları görülmektedir. ABK ve MMOH ölçütleri diğer ölçütlere göre daha düşük değişim katsayısına sahip olmalarına karşın en küçük hataya ulaşan mimarilerin sıklığının diğer ölçütlere nazaran daha az olduğu görülebilmektedir. HKOK, HKOÖK ve NS ölçütlerinin birbirleri ile oldukça benzer karakteristiklere sahip oldukları ve küçük hataya ulaşan mimarilerin sıklığının 0.2 değerinden sonra oldukça azaldığı hatta bu çalışma için en küçük hataya ulaşan sadece 1 tane mimari seçimi gerçekleştirebildikleri görülmektedir. Diğer yandan OMOH, SOMOH, OMGH ve OMÖH ölçütlerinin değişim katsayıları diğer ölçütlere nazaran daha yüksek olmasına karşın en küçük hataya sahip olan mimarilere ulaşma sıklıklarının oldukça fazla sayıda olduğu görülebilmektedir. Ağırlıklı bir kriter olan GAPK'nin ise HKOK, HKOÖK ve NS ölçütlerine göre daha yüksek değişim katsayısına sahip olduğu fakat küçük hataya ulaşan mimarilerin sıklığının 0.1 civarlarında olduğu, benzer şekilde OMOH, SOMOH, OMGH ve OMÖH ölçütlerine göre daha düşük değişim katsayısına sahip olduğu ancak en küçük hataya ulaşan mimarilerin sıklığının OMOH, SOMOH, OMGH ve OMÖH ölçütlerine göre daha az olduğu sonucuna ulaşılmaktadır.

Çizelge 4.4. İNGİLİZ STERLİNİ döviz kuruna ilişkin sonuçlar


	DOLAR/İNGİLİZ STERLİNİ				
	Test Kümesi ve Tahminleri Arasındaki Korelasyon Değerlerinin Ortalaması	Test Kümesi ve Tahminleri Arasındaki Mutlak Hataların Ortalaması	Bir Adım Ötesi Öngörülerin Ortalaması, Gerçek Değer=1.44132	Bir Adım Ötesi Gerçek Değere Göreceli Yakınlık Yüzdesi	En Çok Sayıda Seçilen Mimari ve Seçilme Sayısı
GAPK	0.99861	0.00259	1.44628	99.65585%	1 - 1 - 1 / 981
ABK	0.99868	0.00258	1.44636	99.65049%	1 - 1 - 1 / 1000
HKOK	0.99848	0.00261	1.44610	99.66805%	1 - 1 - 1 / 960
MMOH	0.44896	0.00888	1.57151	90.96721%	1 - 4 - 1 / 479
OMOH	0.99867	0.00258	1.44633	99.65262%	1 - 1 - 1 / 999
HKOÖK	0.99838	0.00263	1.44598	99.67702%	1 - 1 - 1 / 946
SOMOH	0.99867	0.00258	1.44633	99.65262%	1 - 1 - 1 / 999
OMGH	0.99866	0.00258	1.44633	99.65252%	1 - 1 - 1 / 998
OMÖH	0.99864	0.00258	1.44633	99.65240%	1 - 1 - 1 / 997
NS	0.99848	0.00261	1.44610	99.66805%	1 - 1 - 1 / 960

Çizelge 4.4.'de STERLİN döviz kurlarına ilişkin en iyi uyumu en yüksek ortalama korelasyonla ABK ölçütünün gösterdiği görülmektedir. STERLİN için MMOH ölçütünün 1000 tekrardaki ortalama mutlak hata değeri diğer ölçütlerden daha yüksek çıktığı için daha düşük performansa sahip olduğu söylenebilir. Öngörü performansları açısından, bir adım ötesi gerçek değere (1.44132) en yakın ortalama öngörü 99.67702% ile HKOÖK, en uzak ortalama öngörü ise 90.96721% ile MMOH ölçütünün sahip olduğu görülmektedir. Bir çok ölçüt tarafından en çok sayıda seçilen mimarinin STERLİN için 1-1-1 mimarisi olduğu söylenebilir.


Çizelge 4.5. İNGİLİZ STERLİNİ döviz kuruna ilişkin performans ölçütlerinin hata değerleri sonuçları

	DOLAR/İNGİLİZ STERLİNİ						
	En Küçük Hata Değeri	En Küçük Hata Değerine İlişkin Mimari	En Büyük Hata Değeri	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Ortalaması ve Ortancası		0 - 1 Aralığına Getirilmiş Hata Değerlerinin Standart Sapması	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Değişim Katsayısı
GAPK	0.03621327	3 - 3 - 1	0.03718031	0.9806694	0.999618	0.136543403	13.92348948
ABK	-2.07065172	1 - 1 - 1	-2.07064686	0.1162916	0.0003238	0.260210844	223.7571184
HKOK	0.00439807	3 - 3 - 1	0.00500418	0.9749806	0.9998999	0.148139137	15.19405948
MMOH	0.00014631	1 - 4 - 1	0.00080751	0.4065398	0.5602852	0.247412361	60.85809002
OMOH	0.00165691	1 - 8 - 1	0.00174322	0.9988922	0.9998777	0.031619382	3.165444799
HKOÖK	0.00294753	3 - 4 - 1	0.00345629	0.970298	0.9999155	0.148430843	15.29744922
SOMOH	0.00165271	1 - 8 - 1	0.00173732	0.9988915	0.9998768	0.031619358	3.165444825
OMGH	0.00249862	1 - 8 - 1	0.00261544	0.9987959	0.9998671	0.031735853	3.177411213
OMÖH	0.21180257	1 - 8 - 1	0.22131574	0.9986488	0.9998598	0.032140463	3.218394928
NS	0.01702544	3 - 3 - 1	0.02204153	0.9748214	0.9998935	0.148619035	15.24577076

Çizelge 4.5. 'de İNGİLİZ STERLİNİ için tüm performans ölçütlerine ilişkin 1000 tekrar arasından en küçük hata değerleri, en küçük hata değerlerine ilişkin mimariler ve en büyük hata değeriyle birlikte hatalara ilişkin değişim katsayıları verilmektedir. ABK ve MMOH ölçütleri dışında 3-3-1 ve 1-8-1 mimarileri 1000 tekrar arasında en küçük hataya sahip mimariler olarak seçilmiştir. ABK ölçütünün en yüksek değişime sahip olduğu ayrıca MMOH ölçütünde diğer ölçütlere göre oldukça yüksek değişime sahip olduğu görülmektedir.



Şekil 4.12. İNGİLİZ STERLİNİ döviz kuru için 1000 tekrara ait performans ölçütlerinin grafikleri



Şekil 4.12. (devamı)

Şekil 4.12.'de İNGİLİZ STERLİNİ döviz kurunun tüm performans ölçütlerine ilişkin 1000 tekrar için elde edilen ve 0-1 aralığına getirilen en küçük hata değerleri grafikleri verilmektedir. ABK ve MMOH ölçütlerinin diğer ölçütlere göre daha farklı karakteristiklere sahip oldukları görülmektedir. ABK ve MMOH ölçütleri diğer ölçütlere göre daha yüksek değişim katsayısına sahip olmalarına karşın en küçük hataya ulaşan mimarilerin sıklığının diğer ölçütlere nazaran çok daha fazla olduğu görülebilmektedir. GAPK, HKOK, HKOÖK ve NS ölçütlerinin birbirleri ile oldukça benzer karakteristiklere sahip oldukları ve küçük değişim katsayılarına sahip olmalarına karşın 1000 tekrar içerisinde oldukça az sayıda küçük hataya ulaşan mimarilerin olduğu görülmektedir. Diğer yandan OMOH, SOMOH, OMGH ve OMÖH ölçütlerinin en küçük hataya sahip olan mimarilere ulaşma sıklıklarının oldukça az olması değişim katsayılarının diğer ölçütlere nazaran çok daha düşük olmasını açıklamaktadır.

Çizelge 4.6. JAPON YENİ döviz kuruna ilişkin sonuçlar


	DOLAR/JAPON YENİ				
	Test Kümesi ve Tahminleri Arasındaki Korelasyon Değerlerinin Ortalaması	Test Kümesi ve Tahminleri Arasındaki Mutlak Hataların Ortalaması	Bir Adım Ötesi Öngörülerin Ortalaması, Gerçek Değer=113.92	Bir Adım Ötesi Gerçek Değere Göreceli Yakınlık Yüzdesi	En Çok Sayıda Seçilen Mimari ve Seçilme Sayısı
GAPK	0.99998	0.21205	113.26252	99.42285%	1 - 2 - 1 / 712
ABK	0.99998	0.21426	113.23756	99.40095%	1 - 2 - 1 / 549
HKOK	0.99998	0.21232	113.24898	99.41097%	1 - 2 - 1 / 720
MMOH	0.99416	0.35655	113.24415	99.40673%	1 - 8 - 1 / 291
OMOH	0.99998	0.21210	113.26630	99.42617%	1 - 2 - 1 / 701
HKOÖK	0.99998	0.21203	113.25174	99.41340%	1 - 2 - 1 / 714
SOMOH	0.99998	0.21210	113.26630	99.42617%	1 - 2 - 1 / 701
OMGH	0.99552	0.34438	113.41238	99.55440%	3 - 1 - 1 / 824
OMÖH	0.99998	0.21201	113.25326	99.41473%	1 - 2 - 1 / 716
NS	0.99998	0.21232	113.24898	99.41097%	1 - 2 - 1 / 720

Çizelge 4.6’da YEN döviz kuru için MMOH ve OMGH ölçütleri haricindeki diğer ölçütlerin oldukça yüksek ortalama korelasyonla yüksek uyum performansına sahip oldukları görülmektedir. En iyi hata performansı ile OMÖH en düşük ortalama mutlak hataya, öngörü performansı olarak bir adım ötesi gerçek değere (113.92) en yakın ortalama öngörüye ise 99.55440% OMGH ölçütünün sahip olduğu sonucuna varılmaktadır. YEN döviz kuru için ağırlıklı olarak bir çok performans ölçütü tarafından 1-2-1 mimarisinin seçildiği görülmektedir.


Çizelge 4.7. JAPON YENİ döviz kuruna ilişkin performans ölçütlerinin hata değerleri sonuçları

	DOLAR/JAPON YENİ						
	En Küçük Hata Değeri	En Küçük Hata Değerine İlişkin Mimari	En Büyük Hata Değeri	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Ortalaması ve Ortancası		0 - 1 Aralığına Getirilmiş Hata Değerlerinin Standart Sapması	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Değişim Katsayısı
GAPK	0.07564817	1 - 2 - 1	0.13036486	0.6545338	0.4357912	0.267266063	40.83304368
ABK	-0.63160885	1 - 2 - 1	-0.46648049	0.8831603	0.7953228	0.113771338	12.88229726
HKOK	0.1610959	1 - 2 - 1	0.2509313	0.7689974	0.627192	0.178892817	23.26312383
MMOH	0.0202688	1 - 8 - 1	0.21342012	0.2049465	0.1478124	0.175175286	85.47368192
OMOH	0.00130011	1 - 2 - 1	0.00234754	0.6581872	0.4409539	0.26633627	40.46512483
HKOÖK	0.00147895	1 - 2 - 1	0.00240344	0.723952	0.5517684	0.211989158	29.28221031
SOMOH	0.00129902	1 - 2 - 1	0.00234465	0.6581018	0.4408651	0.266352258	40.47280329
OMGH	0.14398215	2 - 2 - 1	0.25671851	0.974127	0.9999997	0.077073756	7.912085217
OMÖH	0.10543871	1 - 2 - 1	0.18632382	0.6776874	0.469807	0.255255607	37.66568833
NS	0.00185962	1 - 2 - 1	0.00451195	0.7372366	0.5762112	0.200793817	27.23600669

Çizelge 4.7. 'de JAPON YENİ için tüm performans ölçütlerine ilişkin 1000 tekrar arasından en küçük hata değerleri, en küçük hata değerlerine ilişkin mimariler ve en büyük hata değeriyle birlikte hatalara ilişkin değişim katsayıları verilmektedir. MMOH ve OMGH ölçütleri dışında 1-2-1 mimarisi 1000 tekrar arasında en küçük hataya sahip mimariler olarak seçilmiştir. MMOH ölçütünün en yüksek değişime sahip olduğu ve OMGH ölçütünde diğer ölçütlere göre oldukça düşük değişime sahip olduğu görülmektedir.



Şekil 4.13. JAPON YENİ döviz kuru için 1000 tekrara ait performans ölçütlerinin grafikleri



Şekil 4.13. (devamı)

Şekil 4.13.'de YEN döviz kurunun tüm performans ölçütlerine ilişkin 1000 tekrar için elde edilen ve 0-1 aralığına getirilen en küçük hata değerleri grafikleri verilmektedir. MMOH ve OMGH ölçütlerinin diğer ölçütlere göre daha farklı karakteristiklere sahip oldukları görülmektedir. MMOH ve OMGH ölçütleri diğer ölçütlere göre sırasıyla en yüksek ve en düşük değişim katsayılarına sahip oldukları ve aynı zamanda sırasıyla en küçük ve en büyük hata sıklığında mimari seçimine sahip oldukları görülebilmektedir. GAPK, ABK, HKOK, OMOH, HKOÖK, SOMOH, OMÖH ve NS ölçütlerinin birbirleri ile oldukça benzer karakteristiklere sahip oldukları fakat küçük hataya ulaşan mimarilerin sıklığının ABK için 0.8, HKOK, HKOÖK ve NS ölçütleri için 0.6 ve OMOH, SOMOH ve OMÖH ölçütleri için 0.4 değerinden sonra oldukça azaldığı görülmektedir.

4.2.2 Simüle edilen zaman serilerine ilişkin sonuçlar

Bu bölümde simülasyonla üretilen Doğrusal Olmayan Otoregresif, Mevsimsel Otoregresif, Sinüs ve Üstel zaman serileri ile ilgili sonuçlar verilmektedir.

Çizelge 4.8. DOĞRUSAL OLMAYAN OTOREGRESİF veri setine ilişkin sonuçlar


	DOĞRUSAL OLMAYAN OTOREGRESİF				
	Test Kümesi ve Tahminleri Arasındaki Korelasyon Değerlerinin Ortalaması	Test Kümesi ve Tahminleri Arasındaki Mutlak Hataların Ortalaması	Bir Adım Ötesi Öngörülerin Ortalaması, Gerçek Değer=1.2666	Bir Adım Ötesi Gerçek Değere Göreceli Yakınlık Yüzdesi	En Çok Sayıda Seçilen Mimari ve Seçilme Sayısı
GAPK	1.00000	0.00177	1.24240	98.08973%	1 - 2 - 1 / 487
ABK	1.00000	0.00181	1.24257	98.10295%	1 - 1 - 1 / 1000
HKOK	1.00000	0.00177	1.24240	98.08943%	1 - 1 - 1 / 506
MMOH	0.99988	0.00177	1.24864	98.58208%	1 - 3 - 1 / 886
OMOH	0.99993	0.00174	1.24586	98.36258%	1 - 3 - 1 / 428
HKOÖK	1.00000	0.00177	1.24240	98.08943%	1 - 1 - 1 / 504
SOMOH	0.99993	0.00174	1.24586	98.36258%	1 - 3 - 1 / 428
OMGH	0.99993	0.00174	1.24584	98.36101%	1 - 3 - 1 / 424
OMÖH	0.99993	0.00174	1.24584	98.36101%	1 - 3 - 1 / 424
NS	1.00000	0.00177	1.24240	98.08943%	1 - 1 - 1 / 506

Çizelge 4.8’de DOĞRUSAL OLMAYAN OTOREGRESİF veri seti için bütün ölçütlerin benzer şekilde yüksek uyum ve hata performansına sahip olduğu söylenebilir. Bir adım ötesi gerçek değere (1.2666) en yakın ortalama öngörüye sahip olan ölçütün 98.58208% ile MMOH olduğu görülmektedir. DOĞRUSAL OLMAYAN OTOREGRESİF için 1-1-1 ve 1-3-1 mimarilerin çoğunlukta seçildiği söylenebilir.


Çizelge 4.9. DOĞRUSAL OLMAYAN OTOREGRESİF simülasyon verisine ilişkin performans ölçütlerinin hata değerleri sonuçları

	DOĞRUSAL OLMAYAN OTOREGRESİF						
	En Küçük Hata Değeri	En Küçük Hata Değerine İlişkin Mimari	En Büyük Hata Değeri	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Ortalaması ve Ortancası		0 - 1 Aralığına Getirilmiş Hata Değerlerinin Standart Sapması	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Değişim Katsayısı
GAPK	0.0101304	1 - 3 - 1	0.01066382	0.6370701	1	0.37601727	59.0229073
ABK	-2.37162874	1 - 1 - 1	-2.37162874	0.6203874	0.7609649	0.34449847	55.5295704
HKOK	0.00240364	1 - 2 - 1	0.00246551	0.5220688	1	0.49969071	95.7135727
MMOH	0.0004311	1 - 3 - 1	0.00111348	0.4700967	0.4240517	0.17562524	37.3593849
OMOH	0.00141108	1 - 3 - 1	0.00174635	0.6949025	0.6672826	0.12221271	17.5870301
HKOÖK	0.00209349	1 - 2 - 1	0.00218159	0.5220928	1	0.4996648	95.7042193
SOMOH	0.00141352	1 - 3 - 1	0.0017483	0.6973274	0.6670331	0.12273078	17.6001666
OMGH	0.00151863	1 - 3 - 1	0.00179002	0.7236965	0.6808301	0.13399367	18.5151733
OMÖH	0.0636791	1 - 3 - 1	0.07482647	0.7283913	0.6758567	0.13706691	18.8177588
NS	0.00019651	1 - 2 - 1	0.00020675	0.5220679	1	0.49969158	95.7139069

Çizelge 4.9. ’da DOĞRUSAL OLMAYAN OTOREGRESİF için tüm performans ölçütlerine ilişkin 1000 tekrar arasından en küçük hata değerleri, en küçük hata değerlerine ilişkin mimariler ve en büyük hata değeriyle birlikte hatalara ilişkin değişim katsayıları verilmektedir. ABK ölçütü dışında 1-2-1 ve 1-3-1 mimarisi 1000 tekrar arasında en küçük hataya sahip mimariler olarak seçilmiştir. HKOK ve HKOÖK ölçütünün en yüksek değişime sahip olduğu ve OMOH ile SOMOH ölçütlerinde diğer ölçütlere göre oldukça düşük değişime sahip olduğu görülmektedir.



Şekil 4.14. DOĞRUSAL OLMAYAN OTOREGRESİF veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri



Şekil 4.14. (devamı)

Şekil 4.14.'te DOĞRUSAL OLMAYAN OTOREGRESİF için tüm performans ölçütlerine ilişkin 1000 tekrar için elde edilen ve 0-1 aralığına getirilen en küçük hata değerleri grafikleri verilmektedir. MMOH, OMOH, SOMOH, OMGH ve OMÖH ölçütlerinin diğer ölçütlere göre daha farklı karakteristiklere sahip oldukları görülmektedir. Bu ölçütlerin daha düşük değişim katsayılarına sahip olmalarına karşın en küçük hata sıklığında mimari seçiminde çok performanslı olmadıkları görülebilmektedir. GAPK, ABK, HKOK, HKOÖK ve NS ölçütlerinin birbirleri ile oldukça benzer karakteristiklere sahip oldukları ve en küçük hata sıklığında mimari seçiminde diğer ölçütlere nazaran daha performanslı oldukları sonucuna ulaşılabilmektedir. Ancak bu ölçütler arasında en küçük hata sıklığının GAPK için 0.2 değerinden sonra oldukça azaldığına dikkat çekmenin gerekli olduğu düşünülmektedir.

Çizelge 4.10. MEVSİMSSEL OTOREGRESİF veri setine ilişkin sonuçlar


	MEVSİMSSEL OTOREGRESİF				
	Test Kümesi ve Tahminleri Arasındaki Korelasyon Değerlerinin Ortalaması	Test Kümesi ve Tahminleri Arasındaki Mutlak Hataların Ortalaması	Bir Adım Ötesi Öngörülerin Ortalaması, Gerçek Değer=-0.6042	Bir Adım Ötesi Gerçek Değere Göreceli Yakınlık Yüzdesi	En Çok Sayıda Seçilen Mimari ve Seçilme Sayısı
GAPK	0.99711	0.47463	-0.76527	73.34235%	1 - 1 - 1 / 698
ABK	0.99967	0.48526	-0.73192	78.86058%	1 - 1 - 1 / 1000
HKOK	0.98935	0.46865	-0.72699	79.67808%	3 - 1 - 1 / 680
MMOH	0.86471	0.89942	-0.96351	40.53071%	6 - 1 - 1 / 749
OMOH	0.99941	0.48424	-0.73327	78.63838%	1 - 1 - 1 / 946
HKOÖK	0.99964	0.48514	-0.73193	78.85953%	1 - 1 - 1 / 960
SOMOH	0.98174	0.62820	-0.74292	77.04147%	1 - 1 - 1 / 954
OMGH	0.88455	0.60440	-0.72063	80.72971%	2 - 3 - 1 / 89
OMÖH	0.96697	0.45734	-0.90716	49.85769%	6 - 1 - 1 / 652
NS	0.98935	0.46865	-0.72699	79.67808%	3 - 1 - 1 / 680

Çizelge 4.10'da MEVSİMSSEL OTOREGRESİF için en iyi uyum performansına en yüksek ortalama korelasyonla ABK, en iyi hata performansına en düşük ortalama mutlak hata ile OMÖH ve en iyi öngörü performansı 80.72971% ile en yakın ortalama öngörü değerine (-0.6042) sahip olan OMGH ölçütü tarafından verilmektedir. Bir çok ölçüt tarafından en çok sayıda seçilen mimari 1-1-1 olarak görülmektedir.


Çizelge 4.11. MEVSİMSEL OTOREGRESİF simülasyon verisine ilişkin performans ölçütlerinin hata değerleri sonuçları

	MEVSİMSEL OTOREGRESİF						
	En Küçük Hata Değeri	En Küçük Hata Değerine İlişkin Mimari	En Büyük Hata Değeri	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Ortalaması ve Ortancası		0 - 1 Aralığına Getirilmiş Hata Değerlerinin Standart Sapması	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Değişim Katsayısı
GAPK	0.35019123	7 - 3 - 1	0.42944327	0.9208269	0.9999923	0.13813382	15.0010629
ABK	0.0480376	1 - 1 - 1	0.04844659	0.7049864	0.8065637	0.23311279	33.0662806
HKOK	0.4944894	7 - 3 - 1	0.59904435	0.8023997	0.8748295	0.12327851	15.3637278
MMOH	0.20327891	5 - 2 - 1	0.32262185	0.7353182	0.7995841	0.15603133	21.2195654
OMOH	0.27501474	2 - 2 - 1	0.30305857	0.9858374	0.999999	0.1025631	10.403653
HKOÖK	0.30512978	2 - 2 - 1	0.30556327	0.8955088	0.9999372	0.2320773	25.9156913
SOMOH	0.31360058	2 - 3 - 1	0.3568756	0.9817499	0.9993015	0.09273798	9.44619249
OMGH	0.56838444	6 - 4 - 1	1.05603582	0.6715713	0.6910437	0.17173428	25.5720111
OMÖH	0.28087337	7 - 3 - 1	0.34921877	0.7927609	0.8360102	0.11571966	14.5970438
NS	0.10269193	7 - 3 - 1	0.15070938	0.7886916	0.8643597	0.12769008	16.1901148

Çizelge 4.11. 'de MEVSİMSEL OTOREGRESİF için tüm performans ölçütlerine ilişkin 1000 tekrar arasından en küçük hata değerleri, en küçük hata değerlerine ilişkin mimariler ve en büyük hata değeriyle birlikte hatalara ilişkin değişim katsayıları verilmektedir. Yapılan 1000 tekrar arasından seçilen en küçük hataya sahip mimariler performans ölçütleri açısından oldukça çeşitlilik gösterdiği görülmektedir. ABK ölçütünün en yüksek değişime sahip olduğu ve SOMOH ölçütünün en düşük değişime sahip olduğu görülmektedir.



Şekil 4.15. MEVSİMSEL OTOREGRESİF veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri



Şekil 4.15. (devamı)

Şekil 4.15.'te MEVSİMSEL OTOREGRESİF için tüm performans ölçütlerine ilişkin 1000 tekrar için elde edilen ve 0-1 aralığına getirilen en küçük hata değerleri grafikleri verilmektedir. OMGH ölçütü dışında bütün ölçütlerin benzer karakteristiklere sahip olduğu sonucu gözlemlenebilmektedir. En küçük hata sıklığında mimari seçiminde aynı performansı gösterecekler de OMGH haricindeki ölçütlerden GAPK, OMOH, HKOÖK ve SOMOH ölçütlerinin 1 değeri etrafında yoğunlaştığı ve ABK, HKOK, MMOH, OMÖH ve NS ölçütlerinin 0.8 değeri etrafında yoğunlaşmasıyla birlikte daha performanslı ölçütler olduğu sonucuna ulaşılabilmektedir.

Çizelge 4.12. SİNÜS veri setine ilişkin sonuçlar

	SİNÜS				
	Test Kümesi ve Tahminleri Arasındaki Korelasyon Değerlerinin Ortalaması	Test Kümesi ve Tahminleri Arasındaki Mutlak Hataların Ortalaması	Bir Adım Ötesi Öngörülerin Ortalaması, Gerçek Değer=0.0057	Bir Adım Ötesi Gerçek Değere Göreceli Yakınlık Yüzdesi	En Çok Sayıda Seçilen Mimari ve Seçilme Sayısı
GAPK	0.46612	0.29230	0.29521	-4979.10071%	1 - 1 - 1 / 152
ABK	0.47228	0.30455	0.26738	-4490.81719%	1 - 2 - 1 / 320
HKOK	0.52009	0.29548	0.30767	-5197.66182%	1 - 7 - 1 / 106
MMOH	0.31545	0.29919	0.30222	-5102.18230%	1 - 9 - 1 / 295
OMOH	0.34971	0.29480	0.29369	-4952.42646%	1 - 5 - 1 / 221
HKOÖK	0.33817	0.31000	0.27660	-4652.58903%	1 - 2 - 1 / 420
SOMOH	0.36479	0.31867	0.29347	-4948.56215%	9 - 2 - 1 / 89
OMGH	0.22147	0.41957	0.22383	-3726.88114%	5 - 3 - 1 / 92
OMÖH	0.42568	0.28131	0.30850	-5212.29573%	1 - 7 - 1 / 275
NS	0.52009	0.29548	0.31028	-5243.46435%	1 - 7 - 1 / 106


Çizelge 4.12'de SİNÜS için verinin karmaşıklığından dolayı düşük ortalama korelasyon ve oldukça düşük uyum performansı ile birlikte yüksek ortalama mutlak hata ile oldukça kötü hata performansına sahip olduğu gözlemlenmektedir. Fakat ölçütler arasında en yüksek ortalama korelasyonun HKOK ile NS ölçütüne, en düşük ortalama mutlak hatanın ise OMÖH ölçütüne ait olduğu görülebilmektedir. Ortalama öngörü değerleri ise bir adım ötesi gerçek değerden (0.0057) oldukça uzak olduğu sonucu, öngörü performansının bu veri için açıkça kötü olduğu yorumu yapılabilmektedir. SİNÜS, karmaşık yapısını mimari seçiminde de ortaya koymakta ve ölçütler arasında oldukça farklı mimarilerin seçilmesine neden olduğu

görülmektedir. Böylece ölçütlerin hatayı ele alışlarının ne kadar farklı olabildiğini göstermek açısından yararlı olduğu yorumu yapılabilmektedir.


Çizelge 4.13. SİNÜS simülasyon verisine ilişkin performans ölçütlerinin hata değerleri sonuçları

	SİNÜS						
	En Küçük Hata Değeri	En Küçük Hata Değerine İlişkin Mimari	En Büyük Hata Değeri	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Ortalaması ve Ortancası		0 - 1 Aralığına Getirilmiş Hata Değerlerinin Standart Sapması	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Değişim Katsayısı
GAPK	0.49073124	1 - 5 - 1	0.69546299	0.5651242	0.560326	0.15285931	27.0487985
ABK	-0.06041939	2 - 1 - 1	0.19114388	0.3476266	0.3534655	0.19048012	54.7944606
HKOK	0.33248974	12 - 3 - 1	0.41844755	0.7076455	0.7143752	0.15946348	22.534373
MMOH	0.1038239	3 - 9 - 1	0.18643292	0.5079087	0.5183515	0.13696302	26.9660694
OMOH	0.56474672	1 - 5 - 1	0.90272585	0.4984492	0.5266308	0.0893547	17.9265423
HKOÖK	0.71987794	1 - 4 - 1	1.11415429	0.2662343	0.2387523	0.08665778	32.5494401
SOMOH	0.74545686	6 - 6 - 1	0.97858714	0.6954392	0.6908614	0.14909021	21.4382797
OMGH	0.37889299	12 - 5 - 1	1.02134213	0.5983299	0.6083409	0.18591964	31.0730972
OMÖH	0.46979251	3 - 6 - 1	0.60027475	0.5038007	0.4980196	0.12037052	23.8924856
NS	0.62200861	12 - 3 - 1	0.98519445	0.686872	0.6910189	0.16471282	23.9801352

Çizelge 4.13. 'te SİNÜS için tüm performans ölçütlerine ilişkin 1000 tekrar arasından en küçük hata değerleri, en küçük hata değerlerine ilişkin mimariler ve en büyük hata değeriyle birlikte hatalara ilişkin değişim katsayıları verilmektedir. SİNÜS, karmaşık yapısını 1000 tekrar içindeki en küçük hataya sahip mimari seçiminde de ortaya koymakta ve ölçütler arasında oldukça farklı mimarilerin seçilmesine neden olduğu görülmektedir. ABK ölçütünün en yüksek değişime sahip olduğu ve OMOH ölçütünün en düşük değişime sahip olduğu görülmektedir.



Şekil 4.16. SİNÜS veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri



Şekil 4.16. (devamı)

Şekil 4.16.'da SİNÜS için tüm performans ölçütlerine ilişkin 1000 tekrar için elde edilen ve 0-1 aralığına getirilen en küçük hata değerleri grafikleri verilmektedir. Karmaşık yapısından dolayı bütün ölçütlerin kötü performansa sahip oldukları 1000 tekrara ilişkin hataların grafiğinde de hepsinin benzer karakteristiklere sahip olması sonucunu doğurduğu düşünülmektedir. Bütün ölçütlerin benzer davranış göstermelerine rağmen hata sıklığı aralıkları arasında OMOH, HKOÖK ve OMÖH ölçütleri ile diğerleri arasında az da olsa farklılıklar gözlemlenebilmektedir. OMOH, HKOÖK ve OMÖH ölçütleri daha dar bir aralıkta hata sıklığına sahipken diğer ölçütler daha geniş aralıkta mimari seçimi yapma eğiliminde olduğu sonucu çıkarılabilmektedir.

Çizelge 4.14. ÜSTEL veri setine ilişkin sonuçlar


	ÜSTEL				
	Test Kümesi ve Tahminleri Arasındaki Korelasyon Değerlerinin Ortalaması	Test Kümesi ve Tahminleri Arasındaki Mutlak Hataların Ortalaması	Bir Adım Ötesi Öngörülerin Ortalaması, Gerçek Değer=-1.0967	Bir Adım Ötesi Gerçek Değere Göreceli Yakınlık Yüzdesi	En Çok Sayıda Seçilen Mimari ve Seçilme Sayısı
GAPK	0.89217	0.32135	-1.08671	99.08869%	1 - 1 - 1 / 290
ABK	0.89279	0.33276	-1.07288	97.82817%	1 - 1 - 1 / 998
HKOK	0.90139	0.31643	-1.09877	99.81123%	3 - 1 - 1 / 307
MMOH	0.85893	0.42134	-1.05897	96.55948%	3 - 9 - 1 / 221
OMOH	0.85140	0.36415	-1.04493	95.27993%	1 - 2 - 1 / 200
HKOÖK	0.82103	0.40509	-1.05163	95.89034%	1 - 2 - 1 / 273
SOMOH	0.89529	0.30959	-1.07205	97.75240%	5 - 1 - 1 / 431
OMGH	0.86078	0.37672	-1.12083	97.79966%	4 - 3 - 1 / 123
OMÖH	0.89974	0.30544	-1.07517	98.03727%	5 - 1 - 1 / 310
NS	0.90139	0.31643	-1.09521	99.86408%	3 - 1 - 1 / 307

Çizelge 4.14. 'te ÜSTEL veri seti için HKOÖK ölçütü haricindeki ölçütlerin benzer uyum performansına sahip oldukları dolayısıyla da oldukça yakın ortalama korelasyon değerlerine sahip oldukları görülmektedir. En iyi hata performansına en düşük ortalama mutlak hata ile OMÖH ölçütü sahipken NS ölçütünün 99.86408% ile bir adım ötesi gerçek değere (-1.0967) oldukça yakın ortalama öngörüyle yüksek öngörü performansına sahip olduğu görülmektedir. ÜSTEL veri setinin karmaşık yapıya sahip olmasından dolayı seçilen mimariler çeşitlilik göstermektedir.


Çizelge 4.15. ÜSTEL simülasyon verisine ilişkin performans ölçütlerinin hata değerleri sonuçları

	ÜSTEL						
	En Küçük Hata Değeri	En Küçük Hata Değerine İlişkin Mimari	En Büyük Hata Değeri	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Ortalaması ve Ortancası		0 - 1 Aralığına Getirilmiş Hata Değerlerini n Standart Sapması	0 - 1 Aralığına Getirilmiş Hata Değerlerini n Değişim Katsayısı
GAPK	0.3161941	2 - 4 - 1	0.4817475	0.7374119	0.8013161	0.1887505	25.59635
ABK	-0.1058027	1 - 1 - 1	-0.0502124	0.0030125	1.72E-05	0.0547164	1816.3363
HKOK	0.2973307	8 - 4 - 1	0.3907363	0.9189735	0.9499991	0.1157165	12.591934
MMOH	0.1016808	4 - 4 - 1	0.2503133	0.6308476	0.6738385	0.2347415	37.210493
OMOH	0.3405731	10 - 3 - 1	0.7140143	0.7402259	0.7846498	0.1753503	23.688748
HKOÖK	0.4805136	4 - 3 - 1	1.2350848	0.5564877	0.5619747	0.1625415	29.208464
SOMOH	0.3152608	2 - 4 - 1	0.4269097	0.7873281	0.8741978	0.1670524	21.21763
OMGH	0.3686697	5 - 6 - 1	0.7526569	0.508252	0.5223563	0.1859857	36.593212
OMÖH	0.3337198	8 - 4 - 1	0.4918127	0.8154357	0.8654622	0.1539718	18.882155
NS	0.1188776	8 - 4 - 1	0.2052997	0.9106813	0.9435509	0.1242539	13.644058

Çizelge 4.15. 'te ÜSTEL için tüm performans ölçütlerine ilişkin 1000 tekrar arasından en küçük hata değerleri, en küçük hata değerlerine ilişkin mimariler ve en büyük hata değeriyle birlikte hatalara ilişkin değişim katsayıları verilmektedir. Yapılan 1000 tekrar arasından seçilen en küçük hataya sahip mimariler performans ölçütleri açısından oldukça çeşitlilik gösterdiği görülmektedir. ABK ölçütünün oldukça yüksek değişime sahip olduğu görülmektedir.



Şekil 4.17. ÜSTEL veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri



Şekil 4.17. (devamı)

Şekil 4.17.'de ÜSTEL için tüm performans ölçütlerine ilişkin 1000 tekrar için elde edilen ve 0-1 aralığına getirilen en küçük hata değerleri grafikleri verilmektedir. ABK ölçütü dışında bütün ölçütlerin benzer karakteristiklere sahip olduğu sonucu gözlemlenebilmektedir. ABK ölçütünün mimari seçiminde oldukça performanslı olduğu sonucu grafiklerden gözlemlenebilmektedir. En küçük hata sıklığında mimari seçiminde aynı performansı gösterecek de OMGH haricindeki ölçütlerden GAPK, HKOÖK ve SOMOH ölçütlerinin 0.8 değeri etrafında yoğunlaştığı ve HKOK, MMOH, OMÖH ve NS ölçütlerinin de 1 değeri etrafında yoğunlaştığı gözlemlenmektedir.

4.2.3 Gerçek zaman serilerine ilişkin sonuçlar

Bu bölümde Yellowstone gayzer patlama süreleri, Kanada vaşağı ve uçak yolcu sayısı verileri ile ilgili sonuçlar verilmektedir.

Çizelge 4.16. YELLOWSTONE GAYZER PATLAMA SÜRELERİ veri setine ilişkin sonuçlar


	YELLOWSTONE GAYZER PATLAMA SÜRELERİ				
	Test Kümesi ve Tahminleri Arasındaki Korelasyon Değerlerinin Ortalaması	Test Kümesi ve Tahminleri Arasındaki Mutlak Hataların Ortalaması	Bir Adım Ötesi Öngörülerin Ortalaması, Gerçek Değer=4.467	Bir Adım Ötesi Gerçek Değere Göreceli Yakınlık Yüzdesi	En Çok Sayıda Seçilen Mimari ve Seçilme Sayısı
GAPK	-0.325718294	1.284709161	3.54149832	79.28136%	6 - 8 - 1 / 38
ABK	-0.801686592	1.518832043	3.051481345	68.31165%	1 - 1 - 1 / 586
HKOK	-0.410797867	1.304278673	3.473594112	77.76123%	6 - 5 - 1 / 35
MMOH	-0.227193399	1.401782223	3.488078564	78.08548%	6 - 10 - 1 / 50
OMOH	-0.233599066	1.299749777	3.479333808	77.88972%	6 - 8 - 1 / 39
HKOÖK	-0.312282484	1.337994102	3.269821407	73.19949%	4 - 10 - 1 / 35
SOMOH	-0.29594682	1.288703023	3.65345853	81.78774%	6 - 8 - 1 / 52
OMGH	-0.415910306	1.357246658	3.156771115	70.66871%	4 - 5 - 1 / 27
OMÖH	-0.274198591	1.2780587	3.616433246	80.95888%	6 - 8 - 1 / 51
NS	-0.410797867	1.304278673	3.473594112	77.76123%	6 - 5 - 1 / 35

Çizelge 4.16. 'da YELLOWSTONE GAYZER PATLAMA SÜRELERİ veri seti oldukça karmaşık yapısından dolayı bütün ölçütler tarafından oldukça kötü bir performans gösterdiği görülmektedir. Negatif ortalama korelasyonların arasında en kötü değere ABK ölçütü sahipken, OMÖH en düşük ortalama mutlak hataya ve bir adım ötesi gerçek değere (4.467) 81.78774% ile en yakın ortalama öngörüye sahip ölçütün SOMOH olduğu görülmektedir. Her iki veri setinde karmaşık yapılara sahip olmalarından dolayı seçilen mimariler çeşitlilik göstermektedirler.


Çizelge 4.17. YELLOWSTONE GAYZER PATLAMA SÜRELERİ zaman serisine ilişkin performans ölçütlerinin hata değerleri sonuçları

	YELLOWSTONE GAYZER PATLAMA SÜRELERİ						
	En Küçük Hata Değeri	En Küçük Hata Değerine İlişkin Mimari	En Büyük Hata Değeri	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Ortalaması ve Ortancası		0 - 1 Aralığına Getirilmiş Hata Değerlerinin Standart Sapması	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Değişim Katsayısı
GAPK	0.6331251	4 - 1 - 1	1.10507499	0.688825	0.7228681	0.17847574	25.9101724
ABK	0.47283854	4 - 1 - 1	0.98331729	0.8812164	1	0.20384185	23.131872
HKOK	1.05534472	6 - 1 - 1	1.69061851	0.6924203	0.7353079	0.18058026	26.0795733
MMOH	0.6005761	10 - 12 - 1	1.34994576	0.6096012	0.6296062	0.14915686	24.467939
OMOH	0.32772453	4 - 1 - 1	0.51755549	0.6465065	0.6652936	0.16030954	24.7962767
HKOÖK	0.41807523	4 - 1 - 1	0.66046198	0.6762857	0.7042529	0.16127281	23.8468442
SOMOH	0.28764299	4 - 1 - 1	0.43322034	0.6638063	0.6913409	0.17219038	25.9398543
OMGH	0.80270964	7 - 1 - 1	1.23516439	0.6589145	0.6940813	0.18606312	28.2378236
OMÖH	0.56970766	4 - 1 - 1	0.8925612	0.659695	0.6884187	0.17026612	25.8098251
NS	0.93783794	4 - 1 - 1	2.40674651	0.6506856	0.6902806	0.18720038	28.7697129

Çizelge 4.17. 'de YELLOWSTONE GAYZER PATLAMA SÜRELERİ için tüm performans ölçütlerine ilişkin 1000 tekrar arasından en küçük hata değerleri, en küçük hata değerlerine ilişkin mimariler ve en büyük hata değeriyle birlikte hatalara ilişkin değişim katsayıları verilmektedir. 4-1-1 mimarisinin 1000 tekrar arasında bir çok ölçüt tarafından en küçük hataya sahip mimari olarak seçildiği görülmektedir. Hataların 0-1 aralığına getirildikten sonra hesaplanan değişim katsayıları arasında çok az fark olduğu sonucu görülmektedir.



Şekil 4.18. YELLOWSTONE GAYZER PATLAMA SÜRELERİ veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri



Şekil 4.18. (devamı)

Şekil 4.18.'de YELLOWSTONE GAYZER PATLAMA SÜRELERİ için tüm performans ölçütlerine ilişkin 1000 tekrar için elde edilen ve 0-1 aralığına getirilen en küçük hata değerleri grafikleri verilmektedir. ABK ölçütü dışında bütün ölçütlerin benzer karakteristiklere sahip olduğu sonucu gözlemlenebilmektedir. ABK ölçütünün mimari seçiminde diğer ölçütlere nazaran daha düşük performansa sahip olduğu grafiklerden gözlemlenebilmektedir.

Çizelge 4.18. KANADA VAŞAĞI veri setine ilişkin sonuçlar


	KANADA VAŞAĞI				
	Test Kümesi ve Tahminleri Arasındaki Korelasyon Değerlerinin Ortalaması	Test Kümesi ve Tahminleri Arasındaki Mutlak Hataların Ortalaması	Bir Adım Ötesi Öngörülerin Ortalaması, Gerçek Değer=3396	Bir Adım Ötesi Gerçek Değere Göreceli Yakınlık Yüzdesi	En Çok Sayıda Seçilen Mimari ve Seçilme Sayısı
GAPK	0.99377	0.01632	3095.12961	91.14045%	1 - 1 - 1 / 1000
ABK	0.99377	0.01632	3095.12961	91.14045%	1 - 1 - 1 / 1000
HKOK	0.99377	0.01632	3095.12961	91.14045%	1 - 1 - 1 / 1000
MMOH	0.92466	0.26560	3281.63836	96.63246%	1 - 4 - 1 / 419
OMOH	0.99377	0.01632	3095.12961	91.14045%	1 - 1 - 1 / 1000
HKOÖK	0.99377	0.01632	3095.12961	91.14045%	1 - 1 - 1 / 1000
SOMOH	0.99377	0.01632	3095.12961	91.14045%	1 - 1 - 1 / 1000
OMGH	0.99377	0.01632	3095.12961	91.14045%	1 - 1 - 1 / 1000
OMÖH	0.99377	0.01632	3095.12961	91.14045%	1 - 1 - 1 / 1000
NS	0.99377	0.01632	3095.12961	91.14045%	1 - 1 - 1 / 1000

Çizelge 4.18. 'de KANADA VAŞAĞI verisi için karmaşık olmayan yapısından dolayı MMOH ölçütü haricinde bütün ölçütlerce oldukça yüksek uyum ve hata performansına sahip mimari seçimleri yapıldığı söylenebilmektedir. Ancak MMOH ölçütünün diğer ölçütlere nazaran kötü olan uyum ve hata performansına rağmen (3396) 96.63246% ile en iyi öngörü performansını gösterdiği görülmektedir. Aynı durumun mimari seçiminde de geçerli olduğu ve MMOH haricinde diğer bütün ölçütler tarafından 1-1-1 mimarisinin seçildiği görülmektedir.


Çizelge 4.19. KANADA VAŞAĞI zaman serisine ilişkin performans ölçütlerinin hata değerleri sonuçları

	KANADA VAŞAĞI						
	En Küçük Hata Değeri	En Küçük Hata Değerine İlişkin Mimari	En Büyük Hata Değeri	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Ortalaması ve Ortancası		0 - 1 Aralığına Getirilmiş Hata Değerlerinin Standart Sapması	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Değişim Katsayısı
GAPK	0.06188803	1 - 1 - 1	0.06188804	0.6829712	0.6609136	0.2735252	40.0493006
ABK	-1.52391143	1 - 1 - 1	-1.52391136	0.6830908	0.6610719	0.27352514	40.0422803
HKOK	0.01764457	1 - 1 - 1	0.01764458	0.6830765	0.6610528	0.27352535	40.0431499
MMOH	0.00886682	12 - 4 - 1	0.01886384	0.7581247	0.6706106	0.17266356	22.7750866
OMOH	0.02814546	1 - 1 - 1	0.02814546	0.6837417	0.6619414	0.27351593	40.002814
HKOÖK	0.0302461	1 - 1 - 1	0.03024611	0.6835636	0.661703	0.27351881	40.0136601
SOMOH	0.02783165	1 - 1 - 1	0.02783165	0.6837387	0.6619374	0.27351593	40.0029884
OMGH	0.0162035	1 - 1 - 1	0.01620351	0.6835806	0.6617267	0.27351788	40.0125298
OMÖH	0.38233032	1 - 1 - 1	0.38233041	0.6835553	0.661693	0.27351826	40.0140625
NS	0.0433409	1 - 1 - 1	0.04334092	0.6830765	0.6610528	0.27352536	40.0431516

Çizelge 4.19. 'da KANADA VAŞAĞI için tüm performans ölçütlerine ilişkin 1000 tekrar arasından en küçük hata değerleri, en küçük hata değerlerine ilişkin mimariler ve en büyük hata değeriyle birlikte hatalara ilişkin değişim katsayıları verilmektedir. 1-1-1 mimarisinin 1000 tekrar arasında MMOH ölçütü haricindeki bütün ölçütler tarafından en küçük hataya sahip mimari olarak seçildiği görülmektedir. Hataların 0-1 aralığına getirildikten sonra hesaplanan değişim katsayıları arasında MMOH ölçütü dışında diğer ölçütler arasında çok az fark olduğu sonucuna ulaşılabilmektedir.



Şekil 4.19. KANADA VAŞAĞI veri seti için 1000 tekrara ait performans ölçütlerinin grafikleri



Şekil 4.19. (devamı)

Şekil 4.19.'da KANADA VAŞAĞI için tüm performans ölçütlerine ilişkin 1000 tekrar için elde edilen ve 0-1 aralığına getirilen en küçük hata değerleri grafikleri verilmektedir. MMOH ölçütü dışında bütün ölçütlerin neredeyse aynı karakteristiğe sahip olduğu sonucu gözlemlenebilmektedir. MMOH ölçütünün mimari seçiminde diğer ölçütlere nazaran daha düşük performansa sahip olduğu yani en küçük hataya ulaşma sıklığının daha az olduğu durum grafiklerden gözlemlenebilmektedir.

Çizelge 4.20. UÇAK YOLCU SAYISI veri setine ilişkin sonuçlar


	UÇAK YOLCU SAYISI				
	Test Kümesi ve Tahminleri Arasındaki Korelasyon Değerlerinin Ortalaması	Test Kümesi ve Tahminleri Arasındaki Mutlak Hataların Ortalaması	Bir Adım Ötesi Öngörülerin Ortalaması, Gerçek Değer=432	Bir Adım Ötesi Gerçek Değere Göreceli Yakınlık Yüzdesi	En Çok Sayıda Seçilen Mimari ve Seçilme Sayısı
GAPK	0.97527	14.84261	421.02343	97.45913%	12 - 1 - 1 / 940
ABK	0.97568	14.85616	421.08329	97.47298%	12 - 1 - 1 / 971
HKOK	0.97527	14.84340	421.03861	97.46264%	12 - 1 - 1 / 939
MMOH	-0.35691	13083.96575	426.67131	98.76651%	1 - 3 - 1 / 324
OMOH	0.97569	14.83442	421.09191	97.47498%	12 - 1 - 1 / 940
HKOÖK	0.97575	14.84260	421.05625	97.46673%	12 - 1 - 1 / 947
SOMOH	0.97576	14.83652	421.09156	97.47490%	12 - 1 - 1 / 941
OMGH	0.97484	14.89102	420.89759	97.43000%	12 - 1 - 1 / 926
OMÖH	0.97563	14.83022	421.08587	97.47358%	12 - 1 - 1 / 937
NS	0.97527	14.84340	421.03861	97.46264%	12 - 1 - 1 / 939

Çizelge 4.20. 'de UÇAK YOLCU SAYISI verisi için karmaşık olmayan yapısından dolayı bütün ölçütlerce oldukça yüksek performansa sahip mimari seçimleri yapıldığı söylenebilmekte ancak, negatif ortalama korelasyona sahip MMOH ölçütünün aynı zamanda (432) 98.76651% ile en iyi ortalama öngörüye ve oldukça yüksek öngörü performansına sahip olduğu sonucunun oldukça şaşırtıcı olduğu görülmektedir. En yüksek ortalama korelasyon değeri SOMOH, en düşük ortalama mutlak hata değeri ise OMÖH ölçütü tarafından sağlandığı ve benzer bir şekilde yüksek performans, aynı zamanda mimari seçiminde de bir çok ölçüt tarafından 12-1-1 mimarisinin yüksek tekrarda seçilmesi ile ortaya çıkmaktadır.


Çizelge 4.21. UÇAK YOLCU SAYISI zaman serisine ilişkin performans ölçütlerinin hata değerleri sonuçları

	UÇAK YOLCU SAYISI						
	En Küçük Hata Değeri	En Küçük Hata Değerine İlişkin Mimari	En Büyük Hata Değeri	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Ortalaması ve Ortancası		0 - 1 Aralığına Getirilmiş Hata Değerlerinin Standart Sapması	0 - 1 Aralığına Getirilmiş Hata Değerlerinin Değişim Katsayısı
GAPK	12.3163023	12 - 1 - 1	57.6409698	0.1851671	0.1728402	0.10073162	54.4003906
ABK	4.60046871	12 - 1 - 1	7.86732579	0.1280988	0.1114145	0.11747247	91.7045514
HKOK	13.1417211	12 - 1 - 1	31.0449008	0.2474013	0.2361706	0.09491724	38.3656949
MMOH	0.48880375	1 - 12 - 1	14.4135223	0.593813	0.5819353	0.20410655	34.3721912
OMOH	0.02483904	12 - 3 - 1	0.04967458	0.2748215	0.2647172	0.09449509	34.3841637
HKOÖK	0.02979405	12 - 3 - 1	0.06156725	0.228477	0.2160343	0.09990748	43.7275859
SOMOH	0.02490113	12 - 3 - 1	0.04828584	0.2887945	0.2787033	0.09514232	32.9446445
OMGH	0.34191383	12 - 3 - 1	0.91949127	0.3891596	0.3855888	0.07993066	20.539304
OMÖH	0.23688638	12 - 3 - 1	0.51263599	0.2779657	0.2683171	0.09324296	33.5447723
NS	0.03355359	12 - 3 - 1	0.1872471	0.1756074	0.16308	0.10113793	57.593189

Çizelge 4.21. 'de UÇAK YOLCU SAYISI için tüm performans ölçütlerine ilişkin 1000 tekrar arasından en küçük hata değerleri, en küçük hata değerlerine ilişkin mimariler ve en büyük hata değeriyle birlikte hatalara ilişkin değişim katsayıları verilmektedir. 12-1-1 mimarisinin 1000 tekrar arasında MMOH ölçütü haricindeki bütün ölçütler tarafından en küçük hataya sahip mimari olarak seçildiği görülmektedir. ABK ölçütünün diğer ölçütlere göre daha yüksek değişime sahip olduğu görülebilmektedir.



Şekil 4.20. UÇAK YOLCU SAYISI döviz kuru için 1000 tekrara ait performans ölçütlerinin grafikleri



Şekil 4.20. (devamı)

Şekil 4.20.'de UÇAK YOLCU SAYISI döviz kurunun tüm performans ölçütlerine ilişkin 1000 tekrar için elde edilen ve 0-1 aralığına getirilen en küçük hata değerleri grafikleri verilmektedir. MMOH ölçütünün diğer ölçütlere göre daha farklı karakteristiğe sahip oldukları görülmektedir. GAPK, ABK, HKOK, OMOH, HKOÖK, SOMOH, OMÖH ve NS ölçütlerinin birbirleri ile oldukça benzer karakteristiklere sahip oldukları fakat küçük hataya ulaşan mimarilerin sıklığının ABK için 0.1, GAPK, HKOÖK ve NS ölçütleri için 0.2, HKOK, OMOH, SOMOH ve OMÖH ölçütleri için 0.3 ve OMGH ölçütü için 0.4 değeri etrafında yoğunlaştığı görülmektedir.



5. SONUÇ VE TARTIŞMA

En uygun model seçimi, temelde hata performansı açısından en küçük hataya sahip olan modelin seçimi anlamına gelmekle beraber araştırmacı tarafından en iyi uyum performansına ya da öngörü performansına sahip olan modelin seçimi anlamına da gelebilmektedir. İstatistiksel modellemenin temeli en küçük hatayı veren modele ulaşmak olarak tanımlanmakla birlikte, YSA`da ise sıkça tercih edilen deneme yanılma yöntemiyle oluşturulan mimarilerin arasında en az hataya sahip olanın seçimi olarak tanımlanabilmektedir. YSA ile oluşturulan modellerin içerisinde en uygun mimariyi seçme işlemi istenilen sonuca ulaşmak adına çok önemli bir adımdır. Seçim için kullanılan her bir ölçüt farklı karakteristiklere sahip oldukları için bu işlemi farklı yaklaşımlarla değerlendirmektedir. Çeşitli ölçütleri bir araya getirme yoluyla sahip oldukları avantaj ve deavantajları ortalama bir düzeyde tutarak oluşturulan ağırlıklı ölçütlerin kullanılmasıyla akılcı sonuçlar elde etmek amaçlanmaktadır.

Bu tez çalışmasında, literatürde mevcut olan performans ölçütlerinin tanıtılması, incelenmesi, hangi durumlarda daha iyi performans gösterdiklerinin ortaya çıkarılması amaçlanmıştır. Ayrıca sıkça kullanılan çeşitli ölçütlerin birleşiminden oluşturulan GAPK, ağırlıklı performans ölçütü olarak önerilmiştir. Ele alınan tüm ölçütlerin performanslarının karşılaştırılması doğrultusunda 3 farklı döviz paritesi, 4 farklı yapay veri ve 3 farklı tanınmış gerçek yaşam veri seti ile uygulamalar yapılmıştır.

Elde edilen sonuçlar ile ağırlıklı ölçütlerin kendi aralarında uyum, hata ve öngörü performansları açısından değerlendirme yapıldığında; ABK ölçütünün JAPON YENİ, DOĞRUSAL OLMAYAN OTOREGRESİF ve KANADA VAŞAĞI veri setlerinde GAPK ölçütüyle aynı ortalama korelasyon değerine, YELLOWSTONE GAYZER PATLAMA SÜRELERİ veri seti için ise daha düşük ortalama korelasyon değerine sahip olduğu fakat diğer veri setleri için daha yüksek ortalama korelasyon değerine dolayısıyla daha iyi uyum performansına sahip olduğu sonucuna ulaşılabilmektedir. GAPK ölçütünün İNGİLİZ STERLİNİ ve KANADA VAŞAĞI veri setleri haricinde ABK ölçütünden daha düşük ortalama mutlak hataya dolayısı ile de daha yüksek hata performansına sahip olduğu sonucu çıkarılmıştır. Öngörü performansı açısından ise

incelenen veri setlerinin 5 tanesinde ABK, 4 tanesinde GAPK ölçütünün daha iyi öngörü performansına sahip olduğu ve KANADA VAŞAĞI veri setinde ise aynı öngörü performansını gösterdikleri sonucuna ulaşılmıştır. Ancak detaylı incelendiğinde sonuçlarından da görülebileceği üzere veri setleri arasında en karmaşık yapıya sahip olan YELLOWSTONE GAYZER PATLAMA SÜRELERİ verisinde GAPK ölçütü ABK ölçütüne göre yaklaşık 11%'lik daha yüksek bir öngörü performansı göstermektedir. ABK ölçütü açısından ise MEVSİMSEL OTOREGRESİF verisinde ABK ölçütünün daha iyi olan öngörü performansı GAPK ölçütünden 5%'lik bir fazlalık göstermektedir. 1000 tekrar sonrasında elde edilen hata değerlerinin 0-1 aralığına getirildikten sonra hesaplanan değişim katsayıları açısından karşılaştırıldığında incelenen 10 veri setinin yarısında ABK, diğer yarısında ise GAPK ölçütünün daha düşük değişim katsayısına sahip olduğu görülmektedir. Fakat değişim katsayıları arasındaki farklar incelendiğinde İNGİLİZ STERLİNİ verisinde ABK ölçütünün GAPK ölçütüne göre 16 kat daha yüksek, ÜSTEL veri setinde ise 70 kat daha yüksek olduğu dikkat çekmektedir. Küçük hataya sahip mimarilerin seçim sıklığı açısından 1000 tekrara ilişkin grafikler incelendiğinde ise ABK ölçütünün GAPK ölçütüne göre daha iyi mimari seçimi yaptığı söylenebilmekle birlikte neredeyse bütün veri setleri için elde edilen grafiklerden de görülebileceği üzere iki ölçütün farklı karakteristiklere sahip olduğuna dikkat edilmelidir.

Elde edilen sonuçlar ile genel bir değerlendirme yapmak gerekirse, incelenen performans ölçütlerinin arasında MMOH ölçütünün oldukça düşük uyum ve hata performansına sahip olduğu, ayrıca OMGH ve SOMOH ölçütleriyle beraber oldukça yüksek öngörü performansına sahip olduğu ifade edilebilir. ABK ölçütünün uyum performansı açısından diğer ölçütlerden daha iyi olduğu ve OMÖH ölçütünün incelenen bütün veri setleri için en iyi hata performansına sahip ölçüt olduğu sonucu kolayca görülebilmektedir. 1000 tekrara ilişkin hataların değişim katsayıları incelendiğinde ise ABK ve MMOH ölçütünün diğer ölçütlere nazaran bazı veri setlerinde oldukça yüksek değişim katsayılarına sahip oldukları görülmektedir. Hataların grafikleri incelendiğinde ise hem alternatif mimari seçimi hemde en küçük hataya sahip mimari seçim sıklığı açısından GAPK ölçütünün bütün veri setleri için oldukça tatminkâr sonuçlar sağladığını ayrıca uyum, hata ve öngörü performansı

açısından değerlendirildiğinde hiç bir veri seti için en iyi ya da en kötü performansa sahip olmadığı ve neredeyse her veri için değişken olan sonuçlar arasından en iyi performans gösteren ölçütlere yakın performans gösterme eğiliminde olduğu sonucu çıkarılabilmektedir. İçerdikleri birden fazla ölçütün özelliklerini barındırmaları sayesinde ağırlıklı ölçütlerin kullanımı, uygun model seçimi için oldukça avantajlı hale gelebilmektedir. Sonuç olarak yapay sinir ağlarında mimari seçiminin daha etkin olabilmesi için literatürde kullanılan performans ölçütlerinin ve bu ölçütlerin birleşimleriyle oluşturulan ağırlıklı ölçütlerin sahip oldukları farklı karakteristikleri göz önüne alınarak kullanılması tavsiye edilmektedir.



KAYNAKLAR

- Akaike, H. (1974) A New Look at the Statistical Model Identification, *IEEE Transactions On Automatic Control*, 19: 716–723.
- Aladag, C.H., Egrioglu, E., Gunay, S. ve Basaran, M.A. (2010) Improving weighted information criterion by using optimization, *Journal of Computational and Applied Mathematics*, 233: 2683-2687.
- Anderson, J.A. (1972) A Simple Neural Network Generating An Interactive Memory, *Mathematical Biosciences*, 14: 197 – 220.
- Anderson, J.A. (1986) Cognitive Capabilities Of A Parallel System., *Disordered Systems And Biological Organization*, Springer-Verlag, Berlin.
- Anderson, J.A., Pellionisz, A., Resenfeld, E. (1986) *Neurocomputing 2: Directions For Research.*, Cambridge, MA: MIT Press.
- Awad, M. ve Khanna, R (2015) *Efficient Learning Machines Theories, Concepts, and Applications for Engineers and System Designers*, Apress, New York, USA, 238s.
- Bal, C. ve Demir, S. (2017) Forecasting TRY/USD Exchange Rate with Various Artificial Neural Network Models, *TEM Journal*, 6: 11-16.
- Bal, C., Demir, S. ve Aladag, C.H. (2016) A Comparison of Different Model Selection Criteria for Forecasting EURO/USD Exchange Rates by Feed Forward Neural Network, *Int'l Journal of Computing, Communications & Instrumentation Engg.*, 3: 2349-1477.
- Bouchard, T.J., Lykken, D.T., McGue, M., Segal, N.L. ve Tellegen, A. (1990) Sources of human psychological differences: the Minnesota Study of Twins Reared Apart, *Science*, 250: 223 – 228.
- Box, G.E.P., Jenkins, G.M., ve Reinsel, G.C. (1976) *Time Series Analysis, Forecasting and Control. Third Edition*. Holden-Day, 712s.

- Bryson, A.E. ve Ho, Y.C. (1969) *Applied optimal control: optimization, estimation, and control*, Waltham, MA: Blaisdell, 481s.
- Carpenter, G.A. ve Grossberg, S. (1985) Category Learning and Adaptive Pattern Recognition, a Neural Network Model, *Third Army Conference on Applied Mathematics and Computation*, 86: 37 – 56.
- Carroll, J.B. (1993) *Human Cognitive Abilities: A Survey of Factor-Analytic Studies*, ambridge University Press, Cambridge UK, 819s.
- Collins, E., Ghosh, S. ve Scofield, C. (1988a) An application of a multiple neural network learning system to emulation of mortgage underwriting judgements, *IEEE 1988 International Conference on Neural Networks*, San Diego, CA, USA.
- Cybenko, G. (1989) Approximation by Superpositions of a Sigmoidal Function, *Math. Control Signals Systems*, 2: 303-314.
- Deary, I.J., Whalley, L.J., Lemmon, H., Crawford, J.R. ve Starr, J.M. (2000) The Stability of Individual Differences in Mental Ability from Childhood to Old Age: Follow-up of the 1932 Scottish Mental Survey, *Intelligence*, 28: 49 – 55.
- Deary, I.J. (2001) *Intelligence: A Very Short Introduction*, Oxford University Press, Oxford UK, 152s.
- Egrioglu, E., Aladag, C.H. ve Gunay, S. (2008) A new model selection strategy in artificial neural networks, *Applied Mathematics and Computation*, 195: 591–597.
- Elmas, Ç. (2011) *Yapay Zekâ Uygulamaları*, Seçkin Yayınevi, Ankara, 424s.
- Fausett, L. (1994) *Fundamentals of Neural Networks*, Prentice-Hall Inc., New Jersey, USA, 461s.
- Flynn, J. (1984) The mean IQ of Americans: Massive gains 1932 to 1978, *Psychological Bulletin*, 95: 29 – 51.

- Fukushima, K. (1980) Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position, *Biol. Cybernetic*, 36: 193 – 202.
- Ghosh, S., Collins, E. ve Scofield, C. (1988b) Prediction of mortgage loan performance with a multiple neural network learning system, *Abstracts of the First Annual INNS Meeting*, 1, 439.
- Grossberg, S. (1976) Adaptive Pattern Classification And Universal Recoding, 1: Parallel Development And Coding Of Neural Feature Detectors, *Biological Cybernetics*, 23: 121 – 134.
- Grossberg, S. (1982) *Studies of Mind and Brain*, Boston, Reidel.
- Günay, S., Eğrioğlu, E. Ve Aladağ, Ç.H. (2007) Tek Değişkenli Zaman Serileri Analizine Giriş, Hacettepe Üniversitesi Yayınları, Ankara, 230s.
- Hamzaçebi, C. (2011) *Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı*, Ekin Yayınevi, Bursa, Türkiye, 133s.
- Hardle, W. (1991) *Smoothing Techniques with Implementation in S*. New York: Springer, 262s.
- Haykin, S. (1994) *Neural Networks: A Comprehensive Foundation*, Prentice Hall PTR Upper Saddle River, NJ USA, 696s.
- Hebb, D.O. (1949) *The Organization of Behavior*, Wiley, New York, 437s.
- Hopfield, J.J. (1982) Neural networks and physical systems with emergent collective computational abilities, *Proc Natl Acad Sci USA*, 79: 2554–2558.
- Hopfield, J.J. (1984) Neurons with graded response have collective computational properties like those of two-state neurons, *Proc Natl Acad Sci USA*, 81: 3088–3092.
- Hopfield, J.J. ve Tank, D.W. (1985) “Neural” computation of decisions in optimization problems, *Biological Cybernetics*, 52: 141–152.
- Hopfield, J.J. ve Tank, D.W. (1986) Computing with neural circuits: a model, *Science*, 233: 625–633.

- Jang, J.S.R., Sun, C.T. ve Mizutani, E. (2012) *Neuro-Fuzzy and Soft Computing*, Pearson Education Inc., New Jersey, USA, 614s.
- Kirkpatrick, S., Gelatt, C.D. ve Vecchi, M.P. (1983) Optimization by Simulated Annealing, *Science*, 220: 671-680.
- Koehler, D.A. (2001) Developments in health and safety accounting at Baxter International, *Corporate Social Responsibility and Environmental Management*, 8: 229–239.
- Kohonen, T. (1972) Correlation Matrix Memories, *IEEE Transactions on Computers*, C-21: 353 – 359.
- Kohonen, T. (1988) The ‘Neural’ Phonetic Typewriter, *Computer*, 21: 11 – 22.
- LeCun, Y., Boser, B., Denker, J.S., Henderson, D., Howard, R. E., Hubbard, W. ve Jackel, L. D. (1990) Handwritten digit recognition with a back-propagation network, *Advances in Neural Information Processing Systems*.
- LeCun, Y. (1986) Learning Processes in an Asymmetric Threshold Network, *Disordered systems and biological organization*, 233-240.
- Lippmann, R.P. (1987) An Introduction' to Computing with Neural Nets, *IEEE ASSP Magazine*, 4: 4 – 22.
- Lippmann, R.P. (1989) Pattern classification using neural networks, *IEEE Communications Magazine* , 27: 47 – 50.
- Mcculloch, W.S. and Pitts, W.H. (1943) A logical calculus of the ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics*, 5: 115 – 133.
- Miller, W.T., Sutton, R.S. ve Werbos, P.J. (1990) *Neural networks for control*, The MIT Press, Cambridge MA, 511s.
- Minsky, M. (1954) *Neural Nets and the Brain Model Problem*, Ph.D. dissertation in Mathematics, Princeton.
- Minsky, M. and Papert S.A. (1969) *Perceptrons, An Introduction to Computational Geometry*, The MIT Press, Cambridge MA, 292s.

- Nash, J. E. ve Sutcliffe, J. V. (1970) River flow forecasting through conceptual models, Part I - A discussion of principles, *Journal of Hydrology*, 10: 282–290.
- Nyugen, D. ve Widrow, B. (1989) The Truck Backer-Upper: An Example of Self-Learning in Neural Networks, *International 1989 Joint Conference on Neural Networks*, Washington, DC, USA.
- Parker, D.B. (1985) "Learning Logic," Technical Report TR-47, *Center for Computational Research in Economics and Management Science*, Massachusetts Institute of Technology, Cambridge, MA.
- Parker, D.B. (1982) Learning logic. Invention report S81-64, File 1, *Office of Technology Licensing*, Stanford University.
- Reyes, J., Morales-Esteban, A., ve Martínez-Álvarez, F. (2013) Neural networks to predict earthquakes in Chile. *Applied Soft Computing Journal*, 13(2): 1314–1328.
- Ritter, H., Martinetz, T. ve Schulten, K. (1992) *Neural Computation and Self-Organizing Maps; An Introduction*, Addison-Wesley Longman Publishing Co., Inc. Boston, MA, USA.
- Rosenblatt, F. (1958) The Perceptron: A Probabilistic Model For Information Storage And Organization In The Brain, *Psychological Review*, 65: 386 – 408.
- Rosenblatt, F. (1962) *Principles of neurodynamics: perceptrons and the theory of brain mechanisms*, Spartan Books, 616s.
- Rumelhart, D.E., Hinton, G.E. ve Williams, R.J. (1986) Learning representations by back-propagating errors, *Nature*, 323: 533–536.
- Sejnowski, T.J. ve Rosenberg, C.R. (1986) NETtalk: a parallel network that learns to read aloud, *The Johns Hopkins University Electrical Engineering and Computer Science Technical Report JHU/EECS-86/01*, 32s.
- Shanker, M. S., Hu, M. Y., & Hung, M. S. (1996). Effect of data standardization on neural network training. *Omega*, 24(4), 385–397.
- Shwartz, G. (1978) Estimating the Dimension of a Model, *The Annals of Statistics*, 6: 461 – 464.

- Simon, H.A. (1983) Why Should Machines Learn?, 25 – 37, Michalski, R.S., Carbonell, J.G., Mitchell, T.M., *Machine Learning An Artificial Intelligence Approach*, Palo Alto, CA: Tiago.
- Szu, H.H. ve Hartley, R. (1987) *Fast Simulated Annealing*, Physics Letters A, 122: 157 – 162.
- Bulmer, M.G. (1974) A statistical analysis of the 10-year cycle in Canada, *J. Anim. Ecol.*, 43: 701 – 715.
- Wechsler, D. (1955) *Manual for the Wechsler Adult Intelligence Scale*, Oxford University Press, Oxford UK, 110s.
- Werbos, P.J. (1974) *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*, PhD thesis, Harvard University.
- Widrow, B. ve Hoff, M.E. (1960) Adaptive Switching Circuits, *IRE WESCON Convention Record*, 96 – 104.
- Widrow, B. ve Stearns, S.D. (1985) *Adaptive Signal Processing*, Prentice-Hall, Inc. Upper Saddle River, NJ, USA.
- Widrow, B. ve Lehr, M.A. (1993) Adaptive Neural Networks and their Applications, *International Journal of Intelligent Systems*, 8: 453-507.
- Wiener, N. (1948) *Cybernetics or Control and Communication in the Animal and the Machine*, The MIT Press, Cambridge MA, 232s.
- Willerman, L., Schultz, R. ve Rutledge, J.N. (1991) In vivo brain size and intelligence, *Intelligence*, 15: 223-228.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Çağatay BAL
Uyruk : T.C.
Doğum Yeri : Altındağ – ANKARA
Doğum Tarihi : 02.12.1990
Telefon : 0539 897 32 33
e-posta : cagataybal@mu.edu.tr

Eğitim

Lise	Kocatepe Mimar Kemal Lisesi	2004 – 2008
Lisans	Hacettepe Üniversitesi	2008 – 2012

İş Tecrübesi

Arş. Gör.	Muğla Sıtkı Koçman Üniversitesi	2014 - ...
-----------	---------------------------------	------------

Yabancı Diller

İngilizce	YDS	66,25
	Yökdil	76,25