

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY ZEKA YAKLAŞIMIYLA JEOFİZİK KUYU
LOGLARINDAN KÖMÜR VARLIĞININ
BELİRLENMESİ ; MANİSA, SOMA HAVZASI**

YÜKSEK LİSANS TEZİ

Hamza KARAMAN

Enstitü Anabilim Dalı : JEOFİZİK MÜHENDİSLİĞİ

Tez Danışmanı : Yrd.Doç.Dr. Can KARAVUL

Ocak 2017

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY ZEKA YAKLAŞIMIYLA JEOFİZİK KUYU
LOGLARINDAN KÖMÜR VARLIĞININ
BELİRLENMESİ ; MANİSA, SOMA HAVZASI**

YÜKSEK LİSANS TEZİ

Hamza KARAMAN

Enstitü Anabilim Dalı : JEOFİZİK MÜHENDİSLİĞİ

Bu tez 09.01.2017 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.

**Yrd. Doç. Dr.
Can KARAVUL
Jüri Başkanı**

**Yrd. Doç. Dr.
Ayhan KESKİNSEZER
Üye**

**Yrd. Doç. Dr.
Eray YILDIRIM
Üye**

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Hamza KARAMAN

09/01/2017

TEŞEKKÜR

Allah (c.c.)' a hamd ve Rasulü Hz. Muhammed (s.a.v) salattan sonra,

Yüksek lisans eğitimim boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Yrd.Doç.Dr. Can KARAVUL'a,

Bana bu çalışmayı yapabilme fırsatını tanıyan Türkiye Kömür İşletmeleri Genel Müdürlüğü'ne,

Her koşulda yanımda oldukları için canım eşime, kızlarım Beyza ve Medine'ye, dostlarım ve üzerimde emeği olan bütün herkese sonsuz teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER.....	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	v
ŞEKİLLER LİSTESİ.....	vii
TABLolar LİSTESİ.....	ix
ÖZET.....	x
SUMMARY.....	xi
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
YAPAY ZEKA.....	3
2.1. Yapay Zeka Türleri.....	6
2.2. Yapay Sinir Ağları.....	7
2.2.1. Yapay sinir ağlarının tarihçesi.....	8
2.2.2. Yapay sinir ağlarının kullanım alanları.....	8
2.2.3. Yapay sinir ağlarının avantajları ve dezavantajları.....	11
2.2.4. Yapay sinir ağları yapısı.....	14
2.2.5. Yapay sinir ağlarının eğitimi ve testi.....	17
2.2.6. Yapay sinir ağlarının sınıflandırılması.....	18
2.2.6.1. Topolojilerine göre sınıflandırılması.....	18
2.2.6.1.1. İleri beslemeli yapay sinir ağları.....	19
2.2.6.1.2. Geri beslemeli yapay sinir ağları.....	20
2.2.6.2. Öğrenme metodlarına göre sınıflandırılması	22
2.2.6.2.1. Danışmanlı öğrenme.....	23
2.2.6.2.2. Danışmansız öğrenme.....	23

2.2.6.3. Öğrenmenin uygulamaya göre sınıflandırılması.....	24
2.2.6.3.1. Hebb kuralı.....	24
2.2.6.3.2. Hopfield kuralı.....	24
2.2.6.3.3. Delta kuralı.....	25
2.2.6.3.4. Levenberg–Marquardt öğrenme algoritması	25
2.2.6.3.5. Kohonen kuralı.....	26
2.2.6.4. Yapısındaki katmanlara göre sınıflandırılması.....	26
2.2.6.4.1. Tek katmanlı yapay sinir ağları.....	26
2.2.6.4.2. Çok katmanlı yapay sinir ağları.....	27
2.2.7. YSA ile modelleme.....	29
2.2.7.1. YSA modelleme faktörleri.....	30
2.2.7.2. Modelleme adımıyla yapılacak işlemler.....	30
2.3. ANFIS Bulanık Çıkarım Sistemi.....	39
2.3.1. ANFIS bulanık çıkarım sistemi yapısı.....	40
2.3.2. ANFIS ağında kullanılan hibrid öğrenme algoritması.....	42
2.3.3. Bulanık mantığın kullanıldığı bazı uygulamalar.....	44
 BÖLÜM 3.	
JEOFİZİK KUYU LOGLARI.....	45
3.1. Kuyu Logları.....	45
3.2. Uygun Log Ortamları.....	48
3.3. Kömür Aramalarında Kullanılan Kuyu Logu Ölçüleri.....	49
3.3.1. SP logu.....	49
3.3.2. Rezistivite logu.....	49
3.3.3. Gamma-ray logu.....	52
3.3.4. Gamma-gamma logu.....	54
3.3.5. Sonik log.....	59
3.3.6. Nötron logu.....	61
 BÖLÜM 4.	
UYGULAMA.....	65
4.1. Çalışma Alanı Jeolojisi.....	67

4.2. Sondaj Litolojisi(Stratigrafisi) ve Jeofizik Kuyu Logları.....	71
4.3. Çalışmada Kullanılan Modeller.....	79
4.3.1. Yapay sinir ağları modeli.....	80
4.3.2. ANFIS modeli.....	84
BÖLÜM 5.	
SONUÇ VE ÖNERİLER.....	87
KAYNAKLAR.....	89
ÖZGEÇMİŞ.....	93



SİMGELER VE KISALTMALAR LİSTESİ

ABD	: Amerika Birleşik Devletleri
ADALINE	: Adaptive Linear Neuron
ANFIS	: Adaptif Sinir Ağına Dayalı Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System)
API	: Amerikan Petrol Enstitüsü
ART	: Adaptive Resonance Theory
BHC	: Borehole Compensa-ted
BRD	: Bed Resolution Density
CAD	: Bilgisayar Destekli Tasarım
Co	: Kobalt
CPS	: Saniyede Darbe Sayısı
Cs	: Sezyum
ECG	: Electrocardiography
EEG	: Elektroensefalografi
GRNN	: General Regression Neural Network
GY	: Geri Yayılım
GR	: Gamma Ray
HKO	: Hata Kareler Ortalaması
HKOK	: Hata Kareler Ortalaması Karekökü
HKT	: Hata Kareler Toplamı
HRD	: High Resolution Density
K	: Potasyum
KCI	: Potasyum Klorür
LSE	: En Küçük Kareler Tahmini
LSD	: Long Spacing Density
MAE	: Mutlak Ortalama Hata (Mean Absolute Error)

MSE	: Mean Squared Error (Hataların Kareleri Ortalaması)
MSFL	: Microspherically Focused Log
MLP	: Multi-Layered Perceptron
N	: D�ğ�m(Node) Sayısı
OMH	: Ortalama Mutlak Hata
OMYH	: Ortalama Mutlak Y�zde Hata
PBNN	: Probability Based Neural Networks
PNN	: Probabihstic Neural Network
R	: Tahmin Sonu�larının Korelasyon Katsayısı
RBF	: Radyal Tabanlı Fonksiyonlar (Radial Basis Functions)
RBN	: Radial Basis Networks
SOM	: Self Organizing Feature Map
SP	: Self Potansiyel(Spontaneous Potential)
Th	: Toryum
TKİ	: T�rkiye K�m�r İ�letmesi
U	: Uranyum
YSA	: Yapay Sinir A�ları

ŞEKİLLER LİSTESİ

Şekil 2.1. Yapay sinir hücresinin yapısı	15
Şekil 2.2. Geri beslemeli ağ için blok diyagram	21
Şekil 2.3. Tek katmanlı ağ yapısı.....	26
Şekil 2.4. İleri beslemeli ağ için blok diyagram.....	27
Şekil 2.5. Geri yayılım çok katmanlı YSA yapısı.....	28
Şekil 2.6. Momentum değerindeki değişime göre ağırlıkların değişim miktarı.....	37
Şekil 2.7. Eğitimin durdurulması için hata ve iterasyon değerleri.....	37
Şekil 2.8. İki girişli-tek çıkışlı birinci dereceden kural polinomlu ANFIS mimari.	41
Şekil 3.1. Log kaydı için yerüstü ve yeraltındaki ortamlar.....	47
Şekil 3.2. Yeraltında SP gerilimi oluşmasıyla, yerüstündeki elektrokimyasal bir pil geriliminin oluşması arasındaki benzerlik.....	49
Şekil 3.3. Normal log şeması.....	50
Şekil 3.4. Yanal log şeması.....	51
Şekil 3.5. Kumtaşı, şeyl - kömür aralanmasından oluşan bir çökel topluluğunu kesen sondaj kuyusunda alınmış log örnekleri	52
Şekil 3.6. Bazı sedimanter kayaların radyoaktif madde içerikleri	53
Şekil 3.7. Gamma - gamma log aleti ve gamma ışınlarının izlediği yolu gösteren şema	55
Şekil 3.8. Kaya yoğunluğu ile log aleti alıcısındaki c.p.s. (saniyede darbe sayısı) arasındaki ilişki.....	55
Şekil 3.9. Kömürlü bir istife ait BRD, LSD ve kaliper logu örnekleri.....	57
Şekil 3.10. Kömürün kül oranı ile HRD logu c.p.s. değerleri arasındaki ilişki	58
Şekil 3.11. Bir kömür seviyesine ait LSD logu (gamma-gamma) ile belirlenmiş kül yüzdeleri ile kömür karotları üzerinde ölçülmüş kül yüzdelerinin kıyaslanması	58
Şekil 3.12. Sonik (BHC) log aleti	60
Şekil 3.13. Kömürlü bir sahaya ait kuyu logu örnekleri	61

Şekil 3.14. Nötron logu şeması.....	62
Şekil 3.15. Kömürlü bir kuyuya ait gamma-ray ve nötron logları	64
Şekil 4.1. Çalışma alanı lokasyon haritası.....	67
Şekil 4.2. Çalışma alanı jeoloji haritası.....	69
Şekil 4.3. Soma bölgesinin genelleştirilmiş stratigrafik kesiti.....	70
Şekil 4.4. EY-321 kuyusuna ait kuyu logu ve litolojisi.....	74
Şekil 4.5. EY-330 kuyusuna ait kuyu logu ve litolojisi.....	74
Şekil 4.6. EY-333 kuyusuna ait kuyu logu ve litolojisi.....	75
Şekil 4.7. EY-339 kuyusuna ait kuyu logu ve litolojisi.....	75
Şekil 4.8. EY-340 kuyusuna ait kuyu logu ve litolojisi.....	76
Şekil 4.9. EY-341 kuyusuna ait kuyu logu ve litolojisi.....	76
Şekil 4.10. EY-342 kuyusuna ait kuyu logu ve litolojisi.....	77
Şekil 4.11. EY-347 kuyusuna ait kuyu logu ve litolojisi.....	77
Şekil 4.12. EY-348 kuyusuna ait kuyu logu ve litolojisi.....	78
Şekil 4.13. EY-351 kuyusuna ait kuyu logu ve litolojisi.....	78
Şekil 4.14. Soma havzasına ait YSA ve ANFIS uygulamasında eğitim ve test seti olarak kullanılan kuyular.....	79
Şekil 4.15. Uygulamada kullanılan yapay sinir ağının yapısı.....	81
Şekil 4.16. Farklı düğüm sayılarına sahip YSA modellerin eğitim sonuçları.....	82
Şekil 4.17. 4 Kuyuya ait 23008 adet test verisi üzerinden YSA sonuçları.....	83
Şekil 4.18. EY-339 kuyusuna ait 4132 adet test verisi üzerinden YSA sonuçları..	83
Şekil 4.19. EY-342 kuyusuna ait 8301 adet test verisi üzerinden YSA sonuçları..	83
Şekil 4.20. EY-347 kuyusuna ait 3674 adet test verisi üzerinden YSA sonuçları..	84
Şekil 4.21. EY-351 kuyusuna ait 6901 adet test verisi üzerinden YSA sonuçları..	84
Şekil 4.22. Uygulamada kullanılan ANFIS yapısı.....	85

TABLÖLAR LİSTESİ

Tablo 2.1. Bilinen yapay sinir ağı modellerinin tarihsel gelişimi.....	8
Tablo 3.1. Kömür ve bazı minerallerin yoğunlukları	56
Tablo 3.2. Kömür ve diğer bazı kayaların gamma ve gamma-gamma loglarına yansıyan özellikleri	56
Tablo 3.3. Bazı mineral ve kayaların ortalama Δt değerleri ve nötron gözeneklilikleri	63
Tablo 4.1. Kömür kuyularının fiziksel özellikleri.....	71
Tablo 4.2. Farklı jeolojik tabakalar ve karşılık gelen kuyu logu parametreleri.....	72
Tablo 4.3. 4 Kuyuya ait 23008 adet test verisi üzerinden ANFIS sonuçları	86
Tablo 4.4. Test kuyularına karşılık gelen ANFIS sonuçları.....	86

ÖZET

Anahtar kelimeler: Yapay sinir ağıları, adaptif sinirsel bulanık çıkarım sistemi, jeofizik kuyu logları, parametre kestirimi

Son zamanlarda, Yapay Sinir Ağları (YSA) ve Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS) çeşitli mühendislik dallarındaki karmaşık sorunları çözmek için yaygın olarak kullanılmaktadır. Bilinen klasik yöntemlerin aksine bu çalışmada, YSA ve ANFIS yardımıyla kömür tabakalarının varlığına yönelik tahmin çalışması yapılmıştır. Çalışmada nötron, gamma ray ve yoğunluk değerleri giriş parametresi, kömür varlığı ise çıkış parametresi olarak kullanılmıştır. Çalışmada kullanılan datalar TKİ Genel Müdürlüğü'nün İR 75153 nolu ruhsat sahasındaki kömür arama sondajlarından alınmıştır. Soma kömür havzasında mekanik olarak açılan 10 adet sondajın jeofizik kuyu logu dataları kullanılmıştır. 10 sondaj kuyusundan 6 adedi eğitim setinde 4 adedi ise test setinde kullanılmıştır. Güvenilir sonuçlar elde etmek için tüm datalar -1 ve 1 arasında normalize edilmiştir. Eğitim ve test Matlab programının YSA ve ANFIS araç kutularında değerlendirilmiştir. YSA ile yapılan çalışmada sonuçlar kuyu bazında değerlendirildiğinde bölgedeki farklı kuyulardan elde edilen jeofizik kuyu logu verileriyle, yine aynı bölgede yer alan kuyularda % 94,9 ile % 86,4 arasında değişen doğruluk oranlarında kömür varlığının tahmin edilebildiği görülmektedir. Test edilen kuyular birlikte değerlendirildiğinde de doğruluk oranı % 91,6 ya kadar yükselebilmektedir. Oluşturulan ileri beslemeli geri yayımlı YSA modelinde düğüm sayısı arttıkça tahmin hatalarının kabul edilebilir miktarlarda arttığı gözlemlenmiştir. Sonuçlardaki hata oranındaki düşüklük, kömürün çıkarılması sürecinde büyük sahalardan alınacak daha az veri ile zaman ve para tasarrufu sağlanarak kaynakların daha etkin kullanılabileceği noktasında umut vericidir.

DETERMINATION OF COAL PRESENCE WITH GEOPHYSICAL WELL LOGGING BY USING AN ARTIFICIAL INTELLIGENCE APPROXIMATION; MANISA, SOMA BASIN

SUMMARY

Keywords: Artificial neural networks, adaptive neuro fuzzy inference system, well logging, parameter estimation

Recently, Artificial Neural Network (ANN) and Adaptive Neuro Fuzzy Inference System (ANFIS) are used for solving to complex problems in various engineering discipline. Instead to common classical methods, in this study, ANN and ANFIS are used for estimating to presence of coal. In this study , neutron, gamma ray, and density are used as an input parameters, presence of coal is used as an output parameter. Logging data which are measured from 10 mechanical well for coal exploration in Soma Coal Basin area has İR 75153 licence number of General Directorate Of Turkish Coal Enterprises (TKİ), are used. 6 of 10 well data are used in training set, remaining data are used in test set. In order to get reliable results, all the data are normalized between -1 and 1. Training and test data are evaluated with ANN and ANFIS Toolbox in Matlab. When ANN modelling of well results are evaluated individually, estimated rate of coal presence varies between %86,4 and %94,6. If wells data are combined, accuracy rate is calculated as %91,6. It is seen that error of estimation is acceptable when node number is increased in feed-forward backpropagation ANN model. The results in this study present that estimation of coal presence in larger areas can be succeed with less data, time and low costs by using ANN and ANFIS modelling methods.

BÖLÜM 1. GİRİŞ

Literatürde “Artificial Intelligence (AI)” olarak adlandırılan yapay zeka ilk bakışta herkese farklı bir şeyin çağrışımını yaptırmaktadır. Kimilerine göre, yapay zeka kavramı, insanoğlunun yerini alan elektromekanik bir robotu çağrıştırmaktadır. Fakat bu alanla ilgili olan herkes, insanoğlu ile makinalar arasında kesin bir farklılığın olduğu bilincindedir. Bilgisayarlar hiçbir zaman insanoğlunun yaratıcılık, duygu ve mizacının benzeşimini aktarabilme becerisine sahip olamayacaktır. Bununla beraber, bilgisayarların belirli insan davranışlarını (nesneleri alma ve bunları belirli yerlere yerleştirme gibi) yapan makinalara yön vermesi ve belirli bir uzmanlık alanı ile ilgili (veri hesaplaması, tıbbi teşhis gibi) beşeri düşünme sürecinin benzetimini yapan (simule eden) sistemlere beyin olma becerisine sahip olması mümkündür.

Günümüz madenciliğinin karar süreçlerinde öngörü modellemesi önemli roller üstlenmektedir. Uygun sondaj lokasyonlarının belirlenmesinden, yatırım tercihlerinin belirlenmesine kadar yeraltı araştırmalarının her kesiminde öngörü modellemesi önem kazanmaktadır. Özellikle, temelinde ileriye dönük bakış açısı olan Rasyonel Bekleyişler Teorisinin önem kazanmasıyla bu durum daha da belirginleşmiştir.

Doğru tahminin (veya öngörünün) başarılı kararları beraberinde getireceği ve bu şekilde fayda maksimizasyonunun sağlanabileceği gerçeği öngörü modellemesine olan ilgiyi artırmaktadır.

Öngörü modellemesine karşı ilginin artması, model çeşitliliğini de beraberinde getirmiştir. YSA ve ANFIS teknikleri de bu yeni teknikler arasında en önemlilerindendir.

YSA ve ANFIS modelleme teknikleri günümüzde bir çok alanda olduğu gibi madencilikte de uygulama alanı genişleyen bir yapay zeka yöntemleridir. YSA ve ANFIS metodolojiler, veriden öğrenebilme, genelleme yapabilme, sınırsız sayıda değişkenle çalışabilme vb. bir çok önemli özelliğe sahiptir. Bu özellikleri sayesinde oldukça önemli avantajlar sağlayan YSA ve ANFIS metodolojileri diğer alanlarda olduğu gibi öngörü modellemesi alanında da yaygın bir şekilde kullanılmaktadır.

Bu çalışmada, yeni bir yöntem olan YSA ve ANFIS teknolojileri incelenmekte, öngörü modellemesi tekniği olarak Türkiye kömür madenciliğine ait bazı jeofizik kuyu logu değişkenlere uygulanmaktadır. Bu kapsamda, çalışmanın ikinci bölümünde YSA ve ANFIS teorisi ele alınacaktır. Bir taraftan YSA ve ANFIS teknikleri genel olarak ele alınırken diğer taraftan daha sonra kullanılacak modelin alt yapısı oluşturulmaktadır. Değişik modelleme yöntemleri ile tahmin edilen modellere ve model öngörülerine ilişkin bilgileri içermektedir. Üçüncü bölümde kuyu loglarına genel bir giriş yapılarak, kömür arama aşamasında kullanılan Jeofizik kuyu loglarına ait bilgiler içermektedir. Dördüncü bölümde, çalışmanın amacı çerçevesinde, bir performans değerlendirmesine yer verilmekte ve son bölümde ise elde edilen sonuçlar tartışılmaktadır.

BÖLÜM 2. YAPAY ZEKA

Çağdaş dünyada bilgisayarlar ve bilgisayar sistemleri yaşamın vazgeçilmez bir parçası haline gelmiştir. Elimizdeki cep telefonlarından, mutfaklardaki buzdolaplarına kadar birçok alet bilgisayar sistemi ile çalışmaktadır. İş dünyasından kamu işlerine, çevre ve sağlık organizasyonlarından askeri sistemlere kadar hemen hemen her alanda bilgisayarlardan faydalanmak olağan hale gelmiştir. Bunun aksini düşünmek bile teknolojinin nimetlerini hiçe saymak olarak görülmektedir. Teknolojinin gelişmesi izlendiğinde önceleri sadece elektronik veri transferi yapmak ve karmaşık hesaplamaları gerçekleştirmek üzere gerçekleştirilen bilgisayarların zaman içerisinde büyük miktarlardaki verileri filtreleyerek özetleyebilen ve mevcut bilgileri kullanarak olaylar hakkında yorumlar yapabilen nitelikler kazandığı görülmektedir. Günümüzde ise bilgisayarlar hem olaylar hakkında karar verebilmekte hem de olaylar arasındaki ilişkileri öğrenebilmektedir. Matematiksel olarak formülasyonu kurulamayan ve çözülmesi mümkün olmayan problemler sezgisel yöntemler yolu ile bilgisayarlar tarafından çözülebilmektedir. Bilgisayarların bu özelliklerle donatılan ve bu yeteneklerin gelişmesini sağlayan çalışmalar “yapay zeka” çalışmaları olarak bilinmektedir. İlk defa 1950'li yıllarda ortaya çıkan yapay zeka terimi zaman içinde oldukça yoğun ilgi görmüş ve 40 - 50 yıllık bir zaman diliminde hayatın vazgeçilmez parçası olan sistemlerin doğmasına neden olmuştur. Bu sistemler hem araştırmacılar hem de ticari olarak satıcılar tarafından “Zeki Sistemler” olarak adlandırılmaktadır. Zeki sistemlerin geliştirilmesinde yapay zeka biliminin katkısı çok fazladır. Benzer şekilde de zeki sistemlerdeki gelişmeler de yapay zeka biliminde gelişmelere neden olmaktadır [1].

Zeki sistemlerin en temel özellikleri olaylara ve problemlere çözümler üretirken veya çalışırken bilgiye dayalı olarak karar verebilme özelliklerinin olması ve eldeki bilgiler ile olayları öğrenerek, sonraki olaylar hakkında kararlar verebilmelidir Yapay

zeka bilimindeki gelişmeler bu sistemlerde çeşitlendirmeye neden olmaktadır. Bir taraftan donanım teknolojisi gelişmekte ve daha hızlı çalışabilen, daha çok bilgi saklayabilen, daha karmaşık sistemleri ve fonksiyonlarını yerine getiren bilgisayarlar ve bilgisayar sistemleri oluşturulmakta iken diğer taraftan yazılım teknolojisi gelişmekte ve bilgi işleme yetenekleri, öğrenme, karar verebilme, problem çözme, muhakeme yapabilme yöntemleri ve bu yöntemlere dayalı yazılım sistemleri geliştirilmektedir. Bu gelişmeler ise zeki sistemlerin her geçen gün daha yaygın olarak bilinmesine ve gerçek hayatta insanların kullanımına alınmasına neden olmaktadır. Artık bilgisayarlar eskiden olduğu gibi sadece bilgi iletişiminin ve hesaplamaların otomasyonunu yapan sistemler olarak görülmemektedir. İnsan karar verme sürecine oldukça benzer bir karar verme sürecine kavuşmakta ve daha karmaşık fakat kullanışlı sistemler ortaya çıkmaktadır. Çalışmalar laboratuvarından çıkmakta ve her geçen gün daha fazla ticari sistemler ortaya çıkmaktadır. İnsanlar olayları çözmek için her gün biraz daha zeki sistemler geliştirmek için çalışmaktadırlar. Bazı sistemler ise zeki olmadıkları halde işlemleri otomatik olarak gerçekleştirdiklerinden, zeki sistem diye tanıtılmakta ve pazarlanmaktadır. Bunlara otomasyon sistemleri demek daha doğru olur. Yeni çıkan zeki sistemler otomasyon sistemlerinin yerini almaktadır. Her geçen gün gerçek zeki sistemlerin sayısı artmakta ve zeki olmayan otomasyon sistemi ortadan kalkmaktadır. Artık eskisi gibi otomasyon sistemlerine zeki sistemler denmemektedir. Sadece zeka ürünü olan fonksiyonları gerçekleştiren sistemler zeki sistemler olarak adlandırılmaktadır [1].

Bu gelişmeler ve ticari sistemlerin başarılı şekilde uygulanması yapay zeka teknolojisinin gelişimine ilgileri daha çok çekmiş ve yapay zeka önceleri sadece bir ilgi odağı iken bugün artık bir bilim dalı haline gelmiştir. Günümüzde üniversitelerde yapay zeka bölümleri açılmıştır. Yapay zeka mühendisleri (bilgi mühendisleri) yetiştirilmektedir. Yapay zeka bilimine genel bir bakış yapılırsa; Bu bilimin bilginin organizasyonu, öğrenme, problem çözme, teorem ispatlama, bilimsel buluşların modellenmesi gibi birçok konu ile ilgilendiği görülmektedir. Bu yetenekler ile donatılan bilgisayar sistemleri problemlere çözüm üretirken insanın problemleri çözme suresini taklit etmektedir. Özellikle belirli bir algoritma veya formülasyon kullanılarak çözülemeyen problemlerin çözülmesi için yapay zeka sistemleri

geliştirilmektedir. Problemin çözümünü sağlayan bir algoritma geliştirilmiş ise geleneksel bilgisayar sistemleri problemi çözmek için yeterli olmaktadır. Önemli olan problemin çözümünü veren bir formülün olmadığı durumlarda bilgisayarlara problemleri çözdürmektir. Yapay zeka bu görevi üstlenmiş bir bilim dalıdır. Bunu başarabilmek için problem ile ilgili her türlü bilgi ile bilgisayarın donatılmış olması gerekmektedir. Bilginin toplanması derlenmesi ve bilgisayara verilmesi en önemli sorunlardan biridir. Çünkü bilgisayarların sahip olduğu bilgi ne kadar doğru ve geçerli ise sonuçlarda o kadar doğru ve geçerli olacaktır [1].

Yapay zeka, insanın düşünme yapısını anlamak ve bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışmak olarak da tanımlanabilir. Yani programlanmış bir bilgisayarın düşünme girişimidir. Daha geniş bir tanıma göre ise, yapay zeka, bilgi edinme, algılama, görme, düşünme ve karar verme gibi insan zekasına özgü kapasitelerle donatılmış bilgisayarlardır.

Yapay zekanın yaygın bir şekilde araştırma ve uygulama alanı bulan belli başlı alt dalları şöyle özetlenebilir [1].

Uzman sistemler, temelde insan düşüncelerini geliştirmek amacıyla bilgisayar tarafından işlenen yazılımlardır. Uzman sistemler geliştirilirken, belirli bir konuda uzmanlaşmış olan insanların bilgi ve deneyimlerinin bilgisayara aktarılması amaçlanır.

Bulanık mantık, bulanık küme teorisine dayanan matematiksel bir disiplindir. Bulanık mantık; bilgisayarın, sadece bir durumun ya da karşıtının olabileceğini kabul eden mantığının yerine, insan mantığındaki gibi ara değerleri de hesaba katarak karar vermesini sağlar. Örneğin bir bilgisayar için sadece uzun-kısa ya da sıcak-soğuk olabilen bir durum, bulanık mantık kullanılarak uzun-ortadan uzun-orta-ortadan kısa-kısa ya da sıcak-ılık-az soğuk-soğuk-çok soğuk gibi ara değerlere sahip olabilir.

Genetik algoritmalar, geleneksel yöntemlerle çözümü zor veya imkansız olan problemleri sanal olarak evrimden geçirerek en iyi çözümü elde etmeyi amaçlamaktadır.

YSA, insan beyninde bulunan sinir ağlarının işleyişini modelleyen tekniklerdir. Yapay sinir ağlarına, ilgili olaya ait bilgiler örnekler üzerinde eğitilerek verilmektedir. Böylelikle, örnekler sayesinde açığa çıkarılmış özellikler üzerinde çeşitli genelleştirilmeler yapılarak, daha sonra ortaya çıkacak ya da o ana kadar hiç rastlanmamış olaylara da çözümler üretilmektedir.

Yapay zeka uygulama alanı olarak bilgisayarlar ve bilgisayar destekli makineleri kullandığı için bilgisayar bilimlerinin bir alt dalı gibi görünmesine rağmen, gelişebilmesi için konusu insan olan diğer pek çok bilim dalının çalışmalarından da faydalanmaktadır. Bu nedenle biyoloji, fizik, matematik, psikoloji, felsefe ve bilgisayar bilimleri yapay zeka çalışmalarına önemli katkılar sağlamaktadır. Böylece çalışma biçimi pek çok bilim dalının katkısıyla çözülmeye çalışılan beynin fonksiyonları, bilgisayarlar ve robotlar kullanılarak modellenmeye çalışılmaktadır.

2.1. Yapay Zeka Türleri

Yapay zeka konusundaki araştırmalar şu gruplar altında toplanabilir.

- a. Bilgi tabanlı yapay zeka ve uzman sistemler
- b. Doğal diller (Bilgisayar ile doğrudan iletişim)
- c. Beşeri algılama yeteneklerinin simülasyonu (Görme, konuşma, işitme, koklama vs.)
- d. Robotikler (Rutin, kirli ve tehlikeli işler için kullanılan robotikler)
- e. Sinirsel ağlar
- f. Bulanık mantık
- g. Sanal gerçeklik

2.2. Yapay Sinir Ağları

YSA, insan beynindeki nöronların çalışma prensiplerine dayanılarak modellenen sistemlerdir. Kolay ve sınırsız imkanları nedeniyle yapay zeka uygulamalarında en geniş kullanım alanına sahiptir. Yalnızca eleme ve karar verme değil aynı zamanda öğrenme işlevini de gerçekleştirmelerinden dolayı avantajlıdır [2].

YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri otomatik olarak gerçekleştirmek amacıyla gerçekleştirilen, biyolojik sinir sistemlerinin çalışma prensibini temel alan bir bilgi işleme tekniğidir. İnsan beyninin çalışma prensibini yapay olarak modellemeyi amaçlayan YSA, tek katmanlı ya da çok katmanlı olarak düzenlenebilen, çok yoğun, paralel olarak çalışan çok sayıda doğrusal olmayan yapay hücreden (işlemci ünitesi) meydana gelen, dağılmış düzende çalışan bir sistem ya da matematiksel model olarak tanımlanır. Yapay sinir ağlarının temel yapısı, beyne, sıradan bir bilgisayarinkinden daha çok benzemektedir. Yine de birimleri gerçek nöronlar kadar karmaşık olmaması ile birlikte ağların çoğunun yapısı, beyin kabuğundaki bağlantılarla karşılaştırıldığında büyük ölçüde basit kalmaktadır.

İnsan beyninin fonksiyonel özelliklerine benzer şekilde, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır. Örneklerden elde ettiği bilgiler ile kendi deneyimlerini oluşturur ve daha sonra benzer konularda benzer kararları verir.

Yapay sinir ağlarında bilgi işleme, sinir hücresi adı verilen bir çok basit elemanda gerçekleşmektedir. Bir sinir hücresinden gelen sinyal, sinir hücreleri arasındaki ilişkiyi sağlayan bağlantılarla iletilmektedir. Her bir bağlantının bir ağırlık değeri vardır ve girdiyi önemine göre ağırlıklandırarak geçişini sağlamaktadır. Sinir ağı içindeki her bir sinir hücresine ayrı bir aktivasyon fonksiyonu uygulanmaktadır (bu fonksiyon genelde doğrusal olmayan bir fonksiyondur) ve bu fonksiyonun çıkış değeri sayesinde sinir hücresinin çıkış sinyali hesaplanmaktadır. Herhangi bir yapay sinir ağı; sinir hücreleri arasındaki bağlantının bir modeli yani mimarisi, bağlantılar

arasındaki ağırlıkların hesaplanması (bu hesaplama, öğrenme kuralı ya da öğrenme algoritması olarak da adlandırılır) ve aktivasyon fonksiyonu ile tanımlanabilir [3].

2.2.1. Yapay sinir ağlarının tarihçesi

YSA'nın başlangıcından günümüze kadar olan gelişim süreci içinde en iyi bilinen mimarilerinin kısa bir tarihçesi Tablo 2.1.'de görülmektedir.

Tablo 2.1. Bilinen yapay sinir ağı modellerinin tarihsel gelişimi [1].

Yıllar	Ağ Mimarisi
1890	İnsan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması
1911	İnsan beyninin bileşenlerinin belirli bir düzenek ile sinir hücrelerinden oluştuğu fikrinin benimsenmesi
1943	Yapay sinir ağlarına dayalı hesaplama teorisinin ortaya atılması
1957-1962	Tek katmanlı algılayıcının (Perceptron) gelişimi
1956-1962	ADALINE ve Widrow öğrenme algoritmasının gelişimi
1969-1972	Doğrusal ilişkilendiricilerin geliştirilmesi
1972	Korelasyon matrisi belleğinin geliştirilmesi
1974	Geriye yayılım modelinin geliştirilmesi
1978	ART modelinin geliştirilmesi
1982	Kohonen öğrenmesi ve SOM modelinin geliştirilmesi
1982	Hopfield ağlarının geliştirilmesi
1982	Çok katmanlı algılayıcıların geliştirilmesi
1984	Boltzman makinesinin geliştirilmesi
1985	Çok katmanlı algılayıcıların geliştirilmesi
1988	RBF modelling geliştirilmesi
1988	PNN modelling geliştirilmesi
1991	GRNN modelling geliştirilmesi

Doksanlı yılların başlarından itibaren sayısız çalışma ve uygulamalar geliştirilmiş, özellikle yapay sinir ağlarını eğitmek için gerekli süreleri kısaltmak, yeni ve daha verimli öğrenme algoritmaları geliştirmek, zamana bağlı olarak değişen modellere karşılık verebilen ağlar ve silikon sinir ağları geliştirmek, yapılan araştırmaların en önemli amaçlarını oluşturmaktadır.

2.2.2. Yapay sinir ağlarının kullanım alanları

Günümüzde YSA eksik bilgilerle çalışabilme ve normal olmayan verilere çözüm üretebilme yeteneklerinden dolayı pek çok alanda kullanılabilmektedir. Doğrusal

olmayan, çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek veriler ve problemlerin çözümü için özellikle bir matematiksel model ve algoritmanın bulunmaması durumlarında yaygın halde YSA uygulamaları yapılabilmekte ve başarılı sonuçlar elde edilmektedir [1]. Bu amaçla geliştirilmiş ağlar genel olarak şu fonksiyonları yerine getirmektedir :

- a. Probabilistik fonksiyon kestirimleri
- b. Sınıflandırma
- c. İlişkilendirme ve örüntü tanımlama (pattern recognition engine)
- d. Zaman serileri analizleri
- e. Sinyal filtreleme
- f. Veri sıkıştırma
- g. Örüntü tanıma
- h. Doğrusal olmayan sinyal işleme
- i. Doğrusal olmayan sistem modelleme
- j. Optimizasyon
- k. Zeki ve doğrusal olmayan kontrol

YSA bu teorik uygulamaların ötesinde günlük hayatta kullanılan finansal konular, mühendislik ve tıp bilimi gibi bir çok alanda uygulanabilmektedir. Evimizdeki aletlerden cep telefonlarına kadar günlük hayatımızda YSA uygulamaları görmek mümkündür. Bu uygulamalar çok çeşitli olup, en önemlileri aşağıda açıklanmıştır.

Arıza analizi ve tespiti: Bir sistemin, cihazın ya da elemanın düzenli (doğru) çalışma şeklini öğrenen bir yapay sinir ağı yardımıyla bu sistemlerde meydana gelebilecek arızaların tanımlanma olanağı olmaktadır. Bu amaçla YSA, elektrik makinelerinin, uçakların ya da bileşenlerinin, entegre devrelerin v.b. arıza analizinde kullanılmaktadır [4].

Finansal uygulamalar: Makro ekonomik tahminler, kredi kartı hilelerinin tespiti, kredi kartı kurumlarında iflas tahminleri, banka kredilerinin değerlendirilmesi, emlak

kredilerinin yönetilmesi, döviz kuru tahminleri, risk analizleri gibi örneklerde uygulama alanı bulmaktadır [1].

Tıp uygulamaları: EEG ve ECG gibi tıbbi sinyallerin analizi, kanserli hücrelerin analizi, protez tasarımı, transplantasyon zamanlarının optimizasyonu ve hastanelerde giderlerin optimizasyonu gibi konularda uygulanmaktadır [4].

Savunma sanayi uygulamaları: Silahların otomasyonu ve hedef izleme, nesneleri/görüntüleri ayırma ve tanıma, yeni algılayıcı tasarımı ve gürültü önleme gibi alanlarda kullanılmaktadır [4].

Haberleşme uygulamaları: Görüntü ve veri sıkıştırma, otomatik bilgi sunma servisleri, konuşmaların gerçek zamanda çevirisi gibi alanlarda uygulanmaktadır [4].

Üretim uygulamaları: Üretim sistemlerinin optimizasyonu, ürün analizi ve tasarımı, ürünlerin kalite analizi ve kontrolü, planlama ve yönetim analizi gibi alanlarda kullanılmaktadır [4].

Otomasyon ve kontrol uygulamaları: Uçaklarda otomatik pilot sistemi otomasyonu, ulaşım araçlarında otomatik yol bulma ve gösterme, robot sistemlerin kontrolü, doğrusal olmayan sistem modelleme ve kontrolü, elektrikli sürücü sistemlerin kontrolü gibi alanlarda uygulanmaktadır [4].

Güvenlik :Parmak izi tanıma, kredi kartı hileleri saptama, retina tarama, yüz eşleştirme vs. bu örnekler çoğaltılabilir.

Farklı alanlardaki uygulamalar incelendiğinde yapay sinir ağlarının genel olarak şu fonksiyonları gerçekleştirmek amacıyla kullanıldıkları görülmektedir [1].

Tahmin: Bu amaçla kullanılan YSA, ağa sunulan bilgilerden yararlanarak karşılık gelen çıktı değerlerini tahmin etmektedirler.

Sınıflandırma: Bu amaçla kullanılan YSA, kendilerine verilen bilgileri kategorize etmek görevini üstlenmektedirler.

Veri ilişkilendirme: Bu amaçla eğitilen ağlar, ağa sunulan verilerin hatalı olup olmadıklarını belirlemektedirler. Öğrendikleri bilgiler ile eksik bilgileri tamamlamaktadırlar.

Veri filtreleme: Bu amaçla eğitilen ağlar, birçok veri arasından uygun verileri belirleme görevini yerine getirmektedir.

Tanıma ve eşleştirme: Değişik şekil ve örüntülerin tanınması, eksik, karmaşık, belirsiz bilgilerin işlenerek eşleştirme ve tanıma fonksiyonlarını gerçekleştirebilmektedir.

Teşhis: Bu amaçla geliştirilen ağlar, sistemlerin olumsuzluklarının ortaya konulması ve problemlerin belirlenmesi işlemini yerine getirmektedirler.

Yorumlama: Bir olay hakkında toplanan örneklerden elde edilen ve eğitim sonucu oluşturulan bilgileri kullanarak yeri olayların yorumlanması işlemleri bu kapsamda düşünülmektedir.

2.2.3. Yapay sinir ağlarının avantajları ve dezavantajları

YSA'lar makina öğrenmesi gerçekleştirebilirler. Yapay sinir ağlarının temel işlevi zaten bilgisayarın öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında mantıklı kararlar verebilirler.

Bilgi işleme yöntemleri geleneksel programlamadan farklıdır. Bu nedenle geleneksel programlamanın getirdiği bir çok olumsuzluk ortadan kaldırılabilir.

Bilgiler ağın tamamında saklanır. Geleneksel programlamada olduğu gibi bilgiler veri tabanları yada dosyalarda belli bir düzende tutulmaz, ağın tamamına yayılarak

değerler ile ölçülen ağ bağlantılarında saklanmaktadır. Nöronlardan bazılarının işlevini yitirmesi, anlamlı bilginin kaybolmasına neden olmaz.

Örnekleri kullanarak öğrenirler. YSA'nın öğrenebilmesi için örneklerin belirlenmesi, bu örneklerin ağa gösterilerek istenen çıktılara göre ağın eğitilmesi gerekmektedir. Ağın başarısı, seçilen örnekler ile doğru orantılıdır, ağa olay bütün yönleri ile gösterilemezse ağ yanlış çıktılar üretebilir.

Daha önce görülmemiş örnekler hakkında bilgi üretebilirler. YSA'lar eğitimleri sırasında kendilerine verilen örneklerden genellemeler çıkarırlar ve bu genellemeler ile yeni örnekler hakkında bilgi üretebilirler.

Algılamaya yönelik olaylarda kullanılabilirler. YSA'ların en başarılı oldukları alanlar, algılamaya yönelik uygulama alanlarıdır. Bu alanlarda başarıları kanıtlanmıştır.

Örüntü (pattern) ilişkilendirme ve sınıflandırma yapabilirler. YSA'lar kendilerine örnekler halinde verilen örüntüleri kendisi veya diğerleri ile ilişkilendirebilir. Ayrıca kendisine verilen örneklerin kümelenmesi ile, bir sonraki verinin hangi kümeye dahil olacağının karar verilmesi konusunda kullanılabilirler.

Örüntü tamamlama yapabilirler. Ağ eksik bilgileri içeren örüntüler verildiğinde eksik bilgilerin tamamlanması konusunda başarılıdırlar.

Kendi kendine öğrenebilme ve organize etme yetenekleri vardır. YSA'lar online olarak öğrenebilirler ve kendi kendilerini eğitebilirler.

Eksik bilgi ile çalışabilmektedirler. Geleneksel sistemlerin aksine YSA'lar eğitildikten sonra veriler eksik bilgi içerse dahi, çıktı üretebilirler. Bu durum bir performans kaybı yaratmaz, performans kaybı eksik bilginin önemine bağlıdır. Burada bilgilerin önem dereceleri eğitim sırasında öğrenilir.

Hata toleransına sahiptirler. YSA'ların eksik bilgilerle çalışabilmeleri ve bazı hücreleri bozulsa dahi çalışabilmeleri, onları hatalara karşı toleranslı yapar.

Dereceli bozulma (Graceful degradation) gösterirler. Bir ağ, zaman içerisinde yavaş ve göreceli bir bozulmaya uğrar. Ağlar problemin ortaya çıktığı anda hemen bozulmazlar.

Dağıtık belleğe sahiptirler. YSA'larda bilgi ağa dağılmış bir şekilde tutulur. Hücrelerin bağlantı ve ağırlık dereceleri, ağın bilgisini gösterir. Bu nedenle tek bir bağlantının kendi başına anlamı yoktur.

Burada çok temel bazı avantajlardan bahsedilmekle beraber, YSA'ların daha pek çok avantajı vardır.

YSA'ların, pek çok avantajın yanında bazı dezavantajları da vardır. Belli başlı dezavantajları;

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

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

Ağın parametre değerlerinin belirlenmesinde belli bir kural yoktur. YSA'larda öğrenme katsayısı, hücre sayısı, katman sayısı gibi parametrelerin belirlenmesinde belirli bir kural yoktur. Bu değerlerin belirlenmesi için belirli bir standart olmamakla birlikte her problem için farklı bir yaklaşım söz konusu olabilmektedir.

Öğrenilecek problemin ağa gösterimi önemli bir problemidir. YSA'lar nümerik bilgiler ile çalışabilmektedirler. Problemler YSA'lara tanıtılmadan önce nümerik

değerlere çevrilmek zorundadırlar. Burada belirlenecek gösterim mekanizması ağı performansını doğrudan etkileyecektir. Bu da kullanıcının yeteneğine bağlıdır.


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

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

2.2.4. Yapay sinir ağları yapısı

Yapay sinir ağlarının içinde bulunan tüm sinir hücreleri bir veya birden fazla girdi alırlar ve tek bir çıktı verirler. Bu çıktı yapay sinir ağının dışına verilen bir çıktı olabileceği gibi başka bir yapay sinir hücresine girdi olarak da verilebilir. Bir yapay sinir hücresi genel olarak beş temel bileşenden oluşmaktadır [3].

- a. Girdiler
- b. Ağırlıklar
- c. Toplama fonksiyonu
- d. Aktivasyon fonksiyonu
- e. Çıktı



Şekil 2.1. Yapay sinir hücresinin yapısı [5].

Girdiler, bir yapay sinir hücresine gelen bilgilerdir. Bu bilgiler dış ortamlardan ya da diğer sinir hücrelerinden gelebilir. Dış ortamlardan gelen bilgiler, ağıın öğrenmesi istenen örnekler tarafından belirlenmektedir.

Ağırlıklar, gelen bilgilerin hücre üzerindeki etkisini belirleyen değerlerdir. Bilgiler, bağlantılar üzerindeki ağırlıklar üzerinden hücreye girmekte ve ağırlıklar yapay sinirde girdi olarak kullanılacak değerlerin göreceli kuvvetini (matematiksel katsayısını) göstermektedirler. Yapay sinir ağı içinde girdilerin hücreler arasında iletimini sağlayan tüm bağlantıların farklı ağırlık değerleri bulunur. Böylelikle ağırlıklar her işlemci elemanın her girdisi üzerinde etki yapmış olur. Ağırlıklar değişken veya sabit değerler olabilirler.

Toplama fonksiyonu, hücreye gelen net girdiyi hesaplayan fonksiyondur ve genellikle girişlerin kendi ağırlıklarıyla çarpımının toplamı;

$$S = \sum X_i W_i \quad (2.1)$$

biçiminde ifade edilir. Yapay sinir ağının yapısına göre toplama fonksiyonu, maksimum, minimum, çarpım veya çeşitli normalizasyon işlemlerinden birisi olarak da ifade edilebilir. Bir problem için en uygun toplama fonksiyonu çeşidini bulmak için herhangi bir formül yoktur. Toplama fonksiyonu genellikle deneme yanılma yoluyla bulunmaktadır. Ayrıca bir yapay sinir ağındaki bütün işlemci elemanların aynı toplama fonksiyonuna sahip olması gibi bir zorunluluk da yoktur. Bazen aynı yapay sinir ağı içindeki işlemci elemanların bazıları aynı toplama fonksiyonunu, diğerleri ise başka fonksiyonları kullanabilirler. Bu tamamen tasarımcının kendi kararına bağlıdır [1].

Elde edilen toplam nöron; aktivasyon olarak adlandırılır. Aktivasyon tamamen nöronun iç durumunu yansıtmaktadır. Ağırlıklar ve girdiler pozitif veya negatif olabilirken aktivasyondan dolayı pozitif, sıfır veya negatif olabilir. Pozitif durum aktive olmuş nöronu, negatif durum pasif olan kapalı nöronu gösterir. Aktivasyon belirlendikten sonra nöron çıktısı belirlemek için sinyal transfer fonksiyonlarını uygular [6].

Aktivasyon fonksiyonları ise bir YSA'da nöronun çıkış genliğini istenilen değerler arasında sınırlamaktadır. Bu değerler çoğunlukla $[0,1]$ veya $[-1,1]$ arasındadır. Lineer ve doğrusal olmayan aktivasyon fonksiyonlarının YSA'larda kullanılması karmaşık ve çok farklı problemlere uygulanmasını sağlamıştır [7].

Uygun aktivasyon fonksiyonunun seçimi tasarımcının farklı fonksiyonları denemeleri sonucunda belirlenmektedir. Ancak çok katmanlı perceptron gibi bazı modeller aktivasyon fonksiyonunun, türevi alınabilir bir fonksiyon olmasını şart koşmaktadır. Ayrıca fonksiyonun seçimi, yapay sinir ağının verilerine ve neyi öğrenmesinin istendiğine de bağlıdır. Aktivasyon fonksiyonu olarak en çok kullanılanlar sigmoid fonksiyon ve hiperbolik tanjant fonksiyonlarıdır.

Çıktı Aktivasyon fonksiyonu tarafından belirlenen değerdir. Bu değer ya başka bir yapay sinir hücresine girdi olarak ya da dış ortama gönderilmektedir. Bir işlemci elemanın birden fazla girdisi olmasına rağmen tek bir çıktısı olmaktadır.

2.2.5 Yapay sinir ağlarının eğitimi ve testi

Yapay sinir ağlarında işlemci elemanlar arasındaki bağlantıların ağırlık değerlerinin değiştirilmesi işlemine “ağın eğitilmesi” denilmektedir. Başlangıçta rastgele atanan bu ağırlık değerleri, ağa gösterilen örneklerle değiştirilmektedir. Amaç, ağa gösterilen örnekler için doğru çıktıları üretecek ağırlık değerlerinin belirlenmesidir. Yapay sinir ağının eğitilmesinde kullanılan girdi ve çıktı çiftlerinden oluşan verilerin tümüne “eğitim seti” adı verilmektedir.

Yapay sinir ağlarının eğitim süreci, belli kurallar çerçevesinde olmaktadır. Bu kurallara öğrenme kuralları adı verilmektedir. Ağırlıkların değiştirilmesi öğrenme kurallarına göre yapılır. Yapay sinir ağında ağırlıkların doğru değerlere ulaşması, örneklerin temsil ettiği problem konusunda ağın genellemeler yapabilme yeteneğine kavuşması demektir. Genelleme, yapay sinir ağının eğitiminde kullanılmamış, ancak aynı evrenden gelen girdi-çıkıtı örneklerini doğru sınıflandırabilme yeteneği olarak tanımlanır. Ağın bu genelleştirme özelliğine kavuşması işlemine “ağın öğrenmesi” denilir.

Yapay sinir ağlarında öğrenme iki aşamada gerçekleşir. Birinci aşamada ağa gösterilen örnek için ağın üreteceği çıktı belirlenir. Bu çıktı değerinin doğruluk derecesine göre, ikinci aşamada ağın bağlantılarının sahip olduğu ağırlıklar değiştirilmektedir. Ağın çıktısının belirlenmesi ve ağırlıkların değiştirilmesi öğrenme kuralına bağlı olarak farklı şekillerde olmaktadır.

Bir yapay sinir ağının eğitiminin tamamlanmasının ardından, ağın öğrenip öğrenmediğini (performansını) ölçmek için denemeler yapılarak ağın test edilmesi gerekmektedir. Bir ağı test etmek için ağın eğitimi sırasında görmediği, yani veri setinden test amaçlı olarak ayrılan örnekler kullanılır ve bu örnekler “test seti” adını alır. Test işleminde ağın ağırlık değerleri değiştirilmemektedir. Örnekler ağa gösterilmekte ve ağ eğitimi sırasında belirlenen ağırlık değerlerini kullanarak daha önce görmediği bu örnekler için çıktılar üretmektedir. Elde edilen çıktıların doğruluk

dereceleri ağın öğrenmesi hakkında bilgi vermektedir. Sonuç ne kadar iyi olursa eğitimin performansı da o kadar iyi demektir [1].

Eğitim ve test setleriyle ilgili temel sorun, yeterli eğitim ve test verisi miktarının ne olması gerektiğidir. Sınırsız sayıda veri bulunabilmesi durumunda, yapay sinir ağı mümkün olduğunca çok veriyle eğitilmelidir. Eğitim verisinin yeterli olup olmadığı konusunda emin olmanın yolu, eğitim verisinin miktarının artırılarak, bunun ağın performansında bir değişiklik yaratıp yaratmadığına bakmaktır. Ancak bunun mümkün olmadığı durumlarda yapay sinir ağına eğitim ve test verileri üzerindeki performansının yakın olması da verilerin yeterli olduğuna ilişkin bir gösterge olarak kabul edilebilir. Bununla birlikte eğitim setinin içermesi gereken veri miktarı değişik yapay sinir modellerine ve özellikle problemin gösterdiği karmaşıklığa göre farklılık göstermektedir.

2.2.6. Yapay sinir ağlarının sınıflandırılması

Yapay sinir ağlarının topolojisi, işlemci elemanların birbirleriyle bağlantı şekillerine göre değişiklik gösterir. Problemlerin çözümü için ise, ağına topolojisine göre seçilen öğrenme algoritmaları yardımıyla ağına ağırlıkları belirlenir. YSA topolojileri ve öğrenme metodlarına göre çeşitli sınıflara ayrılabilir. Bu bölümde, yapay sinir ağlarının topolojilerine ve öğrenme metodlarına göre sınıflandırılmalarından bahsedilerek, temel öğrenme kuralları kısaca anlatılmıştır.

2.2.6.1. Topolojilerine göre sınıflandırılması

Ağ topolojisi, yapay sinir ağlarında işlemci elemanlar arasındaki bağlantının şeklidir. YSA için genel topolojik ağlar; ileri beslemeli (feed-forward), geri beslemeli (feedback) veya yinelemeli (recurrent), bellek tabanlı, radyal tabanlı, modül sinir ağı ve Hopfield ağıdır [8]. Bu bölümde ileri beslemeli ve geri beslemeli ağ kuralları kısaca anlatılmıştır.

2.2.6.1.1. İleri beslemeli yapay sinir ağıları

İleri beslemeli ağlarda işlemci elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, girdi katmanından çıktı katmanına tek yönlü bağlantılarla iletilir [4]. Bir katmandaki her işlemci eleman bir sonraki katmandaki tüm elemanlarla bağlantılıdır ancak aynı katmandaki elemanlar arasında herhangi bir bağlantı bulunmamaktadır. Bu nedenle ileri beslemeli yapay sinir ağlarında, işlemci elemanlar arasındaki bağlantılar bir döngü oluşturmamakta ve bu ağlar girilen verilere hızlı bir şekilde çıktı üretebilmektedirler.

İleri beslemeli yapay sinir ağlarında, hücreler katmanlar şeklinde düzenlenmekte ve bir katmandaki hücrelerin çıktıları bir sonraki katmana ağırlıklar üzerinden girdi olarak verilmektedir. Girdi katmanı, dışardan aldığı bilgileri hiçbir değişikliğe uğratmadan ara (gizli) katmandaki hücrelere iletmektedir. Bu bilgi, ara katman ve çıktı katmanında işlenerek ağ çıktısı belirlenir [4].

İleri beslemeli YSA, öğrenme algoritması olarak genellikle geri yayılım öğrenme algoritmasını kullanmakta ve bu nedenle bazen geri yayılım ağları olarak da adlandırılmaktadır. Mühendislikte ve pek çok alanda en çok kullanılan öğrenme algoritması, ileri beslemeli geriye yayılma algoritmasıdır. Bunun en büyük nedeni, öğrenme kapasitesinin yüksek ve algoritmasının basit olmasıdır [9]. Geriye yayılma algoritması, gerçek çıktı ile istenen çıktı arasındaki karesel hatayı minimum yapmak için gradyen azalma algoritmasını (gradyen descent algorithm) kullanmaktadır.

İleri beslemeli ağlarda işlemci elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, girdi katmanından çıktı katmanına tek yönlü bağlantılarla iletilir. Bir katmandaki her işlemci eleman bir sonraki katmandaki tüm elemanlarla bağlantılıdır ancak aynı katmandaki elemanlar arasında herhangi bir bağlantı bulunmamaktadır.

Şekil tanıma, sinyal işleme ve sınıflandırma gibi problemlerde genellikle bu topoloji uygulanmaktadır.

Geri yayılım (GY) algoritması Rumelhart ve diğerleri [10], çok katlı perceptronlara yaygın bir şekilde uygulanan bir öğrenme algoritmasıdır. GY, gradyen azalan bir algoritmadır ve i ile j indisli nöronlar arasındaki bağlantının $\Delta w_{ji}(t)$ değişimini aşağıdaki gibi verir;

$$\Delta w_{ji}(t) = \eta \delta_j x_i + \alpha \Delta w_{ji}(t-1) \quad (2.2)$$

Burada, η öğrenme katsayısı, α momentum katsayısı, t dizin numara sırası, x_i giriş datalarından üretilen gerçek çıktının i indisli elementi ve δ_j j indisli nöronun, çıkış nöronu veya gizli kat nöronu olup olmamasına bağlı olan bir faktördür. Çıkış nöronları için;

$$\delta_j = \left(\frac{\partial f}{\partial net_j} \right) (y_j^{(t)} - y_j) \quad (2.3)$$

ile, gizli nöronlar için ise;

$$\delta_j = \left(\frac{\partial f}{\partial net_j} \right) \sum_q w_{qj} \delta_q \quad (2.4)$$

ile verilir. Eşitlik (2.4) de, $net_j = \sum_i x_i w_{ij}$ ve $y_j^{(t)}$, j indisli işlem elemanı için hedef çıkışıdır.

2.2.6.1.2. Geri beslemeli yapay sinir ağları

Geri beslemeli ya da diğer adıyla yinelemeli YSA, ileri beslemeli ağların aksine dinamik bir yapıya sahiptirler. Geri beslemeli YSA, çıktı veya ara katmanlardaki işlemci elemanların giriş veya önceki ara katmanlardaki işlemci elemanlara geri beslendiği bir yapıya sahiptir. Böylece girdiler hem ileri hem de geri yönde aktarılmış olurlar. Geri beslemeli YSA dinamik hafızaya sahiptir ve bir andaki çıktı hem o andaki hem de daha önceki girdileri yansıtır.

Geri beslemeli yapay sinir ağlarında, en az bir işlemci elemanın çıktısı, kendisine ya da diğer işlemci elemanlara girdi olarak verilmekte ve genellikle geri besleme bir geciktirme elemanı (ara katman veya çıktı katmanındaki aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşımakla görevli eleman) üzerinden yapılmaktadır. Geri besleme, bir katmandaki işlemci elemanlar arasında olduğu gibi katmanlar arasındaki işlemci elemanlar arasında da olabilmektedir. Bu yapısı sayesinde geri beslemeli YSA, doğrusal olmayan dinamik bir davranış gösterirler. Bu sayede, geri beslemenin yapılış şekline göre farklı yapı ve davranışta geri beslemeli YSA elde edilebilir [4].

Geri beslemeli YSA karmaşık bir çalışma düzeneğine sahip olmalarına rağmen, dinamik hafızaları nedeniyle önceden tahmin uygulamalarında başarılı sonuçlar verirler. Şekil 2.2.'de, geri besleme ağ yapısı örneklenmektedir. Burada;


$x(t)$: t nöronlu girdi katmanı,

$y(t)$: t nöronlu girdi katmanına ait gizli katman,

d : gecikme sayısı,

$y(t+d)$: d gecikmeli t nöronlu çıktılar,

$F(W y(t))$: ağı birimlerinde tercih edilen aktivasyon fonksiyonudur.



Şekil 2.2. Geri beslemeli ağ için blok diyagram [13].

Geri yayılma ağılar, çok tabakalı perceptron ile aynı yapıya sahiptirler ve öğrenme yöntemi olarak geri yayılma algoritması kullanırlar. Dolayısıyla, bu ağılar ileri besleme ağılar sınıfına girmektedirler. Bu YSA türünün seçilmesinin temel sebebi öngörü (prediction) ve sınıflandırma işlemleri için oldukça uygun olmasıdır. Diğer bir önemli neden ise doğrusal olmayan yapılar için de oldukça kullanışlı olmasıdır.

İleri beslemeli geri yayılma mimarisi 1970’li yıllarda geliştirilmiştir. Bu mimarinin geliştirilmesinde birbirlerinden bağımsız olarak birkaç araştırmacının katkıları olmuştur. Ortaya çıkışından sonra, hem etkili hem de çok kullanışlı olmasından dolayı büyük bir popülerite kazanmıştır ve hala en çok kullanılan ağ türü olarak bilinmektedir. Çok sayıda farklı uygulama alanında kullanılmaktadır ve en büyük özelliği doğrusal olmayan yapı içeren problemlerde de etkili olabilmesidir.

2.2.6.2. Öğrenme metodlarına göre sınıflandırılması

Yapay sinir ağlarında öğrenmeyi açıklayabilmek için öncelikle öğrenme kavramının açıklanması gerekir. Öğrenme için en uygun tanımlardan biri Simon tarafından önerilen ve geniş kabul gören tanımdır. Bu tanıma göre öğrenme, “zaman içinde yeni bilgilerin keşfedilmesi yoluyla davranışların iyileştirilmesi sürecidir” [1]. Bilgisayarların öğrenebilmesi ise bilgisayara ilgili problem hakkında gerekli bilgilerin verilmesi ile mümkündür. Böylece bilgisayarlar da insanlar gibi zaman içerisinde tecrübe kazanabilmektedirler.

Yapay sinir ağlarında öğrenme örnekler yolu ile sağlanmaktadır. Bilgisayarlar önce kendilerine verilen bir örneğe bakarak bilgi edinmekte, daha sonra ikinci örneğe bakarak biraz daha bilgi edinmekte ve bu işlem, ağ problemle ilgili genellemeler yapabilecek seviyeye gelene kadar devam etmektedir. Bu işlemin matematiksel karşılığı, birtakım metod, kural ve algoritmalar yardımıyla ağdaki işlemci elemanlar arasındaki bağlantı ağırlıklarının sürekli yenilenerek değiştirilmesidir. Yapay sinir ağlarında her ağ modeli kendine göre bir öğrenme algoritması kullanabilse de temel olarak danışmanlı (supervised) öğrenme ve danışmansız (unsupervised) öğrenme olmak üzere iki tür öğrenme metodu bulunur [3].

2.2.6.2.1. Danışmanlı öğrenme

Yapay sinir ağlarında en fazla kullanılan öğrenme metodu olan danışmanlı öğrenmede, yapay sinir ağına örnek olarak bir çıktı (beklenen çıktı) verilir ve bu çıktıyla ağın ürettiği çıktı karşılaştırılır. İki çıktı arasındaki fark hata olarak alınır. Başlangıçta genellikle rassal olarak verilen ağırlıklar ağ tarafından hata minimize edilene kadar döngüler halinde değiştirilir [11]. Genelleştirilmiş delta kuralı ve geri besleme algoritması danışmanlı öğrenme metoduna örnek olarak verilebilir.

2.2.6.2.2. Danışmansız öğrenme

Danışmansız öğrenmede yapay sinir ağına sadece girdiler verilmekte, ulaşılması gereken beklenen çıktılar verilmemektedir. Girişte verilen örnek değerlere bakarak yapay sinir ağı, parametreler arasındaki ilişkileri kendi kendine öğrenir. Yapay sinir ağı daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren örüntüler (patterns) oluşturmak üzere ayarlar. Danışmansız öğrenme genellikle sınıflandırma problemlerinin çözümünde kullanılmaktadır. ART (Adaptive Resonance Theory) danışmansız öğrenmeye örnek olarak verilebilir [4].

Danışmansız öğrenme metodu, yapay sinir ağlarında sürekli araştırılan ve gelişen bir öğrenme metodudur. Bu metod, gelecekte bilgisayarların insan yardımı olmadan öğrenebileceklerinin göstergesidir. Ancak günümüzde sınırlı kullanım alanları bulan ve hala yoğun araştırma konusu olan bir öğrenme metodudur [11].

Ayrıca hem danışmanlı hem de danışmansız öğrenmeyi birlikte kullanan YSA da bulunmaktadır. Bu ağlarda ağırlıkların bir kısmı danışmanlı öğrenmeyle bir kısmı da danışmansız öğrenmeyle ayarlanır. Radyal tabanlı YSA (Radial Basis Networks - RBN) ve olasılık tabanlı YSA (Probability Based Neural Networks - PBNN) bunlara örnek olarak verilebilir.

Bu iki temel öğrenme metodundan başka literatürde destekleyici öğrenme (reinforcement learning) adı verilen bir metod daha bulunmaktadır. Bu metoddan bazı kaynaklarda danışmanlı bazı kaynaklarda danışmansız öğrenmenin bir alt türü

olarak, bazı kaynaklarda ise kendi başına bir öğrenme metodu olarak bahsedilmektedir. Bu metoda göre, yapay sinir ağına sadece girdiler verilmekte, bu girdilere karşılık çıktıları üretmesi beklenmekte ve bu çıktıların ne derece doğru olduğunu belirten bir skor veya derece bildirilmektedir [12].

2.2.6.3. Öğrenmenin uygulamaya göre sınıflandırılması

YSA modellerinin eğitilmesinde kullanılan pek çok öğrenme algoritması bulunur. Bu algoritmalar, yapay sinir ağının topolojisine, karşılaşılan problemin niteliğine göre farklılıklar gösterse de bir çoğunun temel aldıkları öğrenme kuralı Hebb Kuralı ve onun geliştirilmiş versiyonlarıdır. Bunun yanında, farklı öğrenme kuralları da vardır ve bu konuda çalışmalar sürmektedir. Temel öğrenme algoritmaları Hebb Kuralı, Hopfield Kuralı, Delta Kuralı, Levenberg – Marquardt Öğrenme Algoritması ve Kohonen Kuralı'dır.

2.2.6.3.1. Hebb kuralı

Hebb tarafından ve biyolojik öğrenme temel alınarak geliştirilen bu kural bilinen en eski öğrenme kuralıdır. Diğer öğrenme kurallarına da temel olan Hebb Kuralı'na göre, bir yapay sinir hücresi diğer bir yapay sinir hücresinden girdi alırsa ve her iki hücre de yüksek derecede aktif ise (matematiksel olarak aynı işareti taşıyorsa) her iki hücrenin arasındaki bağlantının ağırlığı artırılmalıdır.

2.2.6.3.2. Hopfield kuralı

Hopfield Kuralı, bir farklılık dışında Hebb Kuralına benzer. Bu farklılık, Hopfield Kuralı'nda, bağlantı ağırlığında yapılacak olan değişikliğin büyüklüğünün de belirlenmesidir. Buna göre, girdi ve istenilen çıktının ikisi de aktifse, bağlantı ağırlığı öğrenme katsayısı kadar artırılmakta, aksi durumda ise öğrenme katsayısı kadar azaltılmaktadır. Öğrenme katsayısı genel olarak 0-1 arasında tasarımcı tarafından atanan sabit ve pozitif bir değerdir.

2.2.6.3.3. Delta kuralı

Widrow ve Hoff tarafından geliştirilen bu kural Hebb Kuralının gelişmiş şeklidir. En çok kullanılan kurallardan biri olan Delta Kuralı, yapay sinir hücresinin gerçek çıktısı ile beklenen çıktısı arasındaki farkı azaltmak için yapay sinir ağlarının işlemci elemanları arasındaki bağlantı ağırlık değerlerinin sürekli değiştirilmesi ilkesine dayanır. Bu kuralla, gerçek çıktı ile beklenen çıktı arasındaki hatanın karesi en aza indirilmeye çalışılmaktadır. Bu nedenle En Küçük Kareler Kuralı olarak da adlandırılır. Ayrıca bazı kaynaklarda Widrow-Hoff Kuralı olarak da geçer.

2.2.6.3.4. Levenberg – Marquardt öğrenme algoritması

Levenberg-Marquardt öğrenme algoritması son yıllarda kullanılan en popüler ve diğer algoritmalara alternatif olarak geliştirilmiş algoritmalarındandır. Hızlı ve yüksek performanslı algoritmalar ikiye ayrılmaktadır. Bunlar;

- a. Deneme yanılma tekniklerini kullanan algoritmalar,
 - b. Standart sayısal optimizasyon yöntemlerini kullanan algoritmalar.
- Levenberg-Marquardt öğrenme algoritmasında bu kategori içerisinde yer almaktadır.

Levenberg-Marquardt öğrenme algoritmasına göre, hata değeri bulunduktan sonra nöronlar kendi hatalarını azaltmak için ağırlıklarını ayarlamak durumundadır. Ağırlık değiştirme denklemleri de ağdaki performans fonksiyonunu en küçük yapacak şekilde düzenlenirler. Diğer bir deyişle bu algoritmaya, maksimum komşuluk fikri üzerine kurulmuş bir en küçük kareler tahmin metodu da denilebilir.

Özellikle ileri beslemeli ağlarda kullanılan öğrenme algoritmaları, performans ölçütünü en küçük yapacak ağırlıkları ayarlayabilmek için, performans fonksiyonunun türevini kullanırlar.

2.2.6.3.5. Kohonen kuralı

Kohonen tarafından geliştirilen bu öğrenme kuralı biyolojik sistemlerdeki öğrenmeden esinlenilmiştir. Bu kuralda işlemci elemanlar, ağırlıklarının ayarlanması (öğrenme) için yarışmaktadırlar. Kazanan işlemci elemanın bağlantı ağırlıkları değiştirilmektedir. En uygun çıktıya sahip işlemci elemanın kazandığı kuralda bu işlemci eleman, kendisine komşu işlemci elemanların ağırlıklarının değiştirilmesine de izin vermektedir.


2.2.6.4. Yapısındaki katmanlara göre sınıflandırılması

YSA içerdikleri katman sayısına göre tek katmanlı ve çok katmanlı olarak da sınıflandırılabilirler.

2.2.6.4.1. Tek katmanlı yapay sinir ağı

Tek Katmanlı YSA sadece girdi ve çıktı katmanlarından oluşur. Ara katmanlar bulunmaz. Her ağı bir ya da daha fazla girdisi çıktısı vardır. Şekil 2.3.'te tek katmanlı ağ yapısı gösterilmiştir.

Tek katmanlı algılayıcılarda çıktı fonksiyonu doğrusal bir fonksiyondur. Diğer bir deyişle ağı gönderilen örnekler iki sınıf arasında paylaştırılarak iki sınıfı birbirinden ayıran doğru bulunmaya çalışılır.



Şekil 2.3. Tek katmanlı ağ yapısı [13].

Ağın çıktısı, ağırlıklandırılmış girdi değerlerinin eşik değeri ile toplanması sonucu bulunur. Bu girdi değeri aktivasyon fonksiyonundan geçirilerek ağın çıktısı hesaplanır. Tek katmanlı YSA temel olarak doğrusal özellik gösteren olayları çözmekte başarılı iken doğrusal özellik göstermeyen olayların çözülmesinde yetersiz kalmaktadırlar [13].


2.2.6.4.2. Çok katmanlı yapay sinir ağları

Bu ağ modeli özellikle mühendislik uygulamalarında en çok kullanılan sinir ağı modelidir. Bir çok öğretim algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir.

White [14], günümüzde en çok bilinen ve yaygın biçimde kullanılan yapay sinir ağı sınıflandırma yönteminin çok katmanlı yapay sinir ağı olduğunu ifade etmektedir. Genel amaçlı, esnek ve çoklu katmanlar halinde organize edilmiş nöronlardan oluşan doğrusal olmayan modellerdir. Çok katmanlı yapay sinir ağı hemen hemen her fonksiyonu tahmin etme/yaklaşım özelliğine sahip bir ağıdır. Özellikle tanıma sistemlerinde kullanılmaktadır.

Çok katmanlı yapay sinir ağı modeli, bir giriş, bir ya da daha fazla gizli katman ve bir de çıkış katmanından oluşur. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır.

Şekil 2.4.'de ileri beslemeli YSA için blok diyagram gösterilmiştir. İleri beslemeli ağlara örnek olarak çok katmanlı ağlar ve öğrenme vektör nicelendirme ağları verilebilir.



Şekil 2.4. İleri beslemeli ağ için blok diyagram [13].

Burada;

$X(t)$: t nöronlu girdi,

$\mathcal{C}_a(t)$: t nöronlu gizli katman,


$\mathcal{C}(t)$: t nöronlu çıktı katmanına ait çıktıları göstermektedir.

Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı çok katmanlı yapay sinir ağlarının eğitiminde geri yayılım algoritması kullanılmaktadır.

Geri yayılım algoritması daha önce de bahsedildiği gibi danışmanlı öğrenme yapısına sahip ve birçok uygulamada kullanılan öğrenme algoritmasıdır.

İleri beslemeli, danışmanlı öğrenme kuralını uygulayan geri yayılım öğrenme algoritmasını kullanan örnek bir çok katmanlı yapay sinir ağı modeli Şekil 2.5.'te verilmiştir.

Çok katmanlı yapay sinir ağlarında girdi katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı tamamen uygulanan problemin girdi sayısına bağlıdır. Gizli katman sayısı ve gizli katmanlardaki işlem elemanı sayısı ise, deneme-yanılma yolu ile bulunabilir. Çıkış katmanındaki eleman sayısı ise yine uygulanan probleme göre deneme-yanılma ile belirlenebilir.



Şekil 2.5. Geri yayılım çok katmanlı YSA yapısı [4].

Çok katmanlı yapay sinir ağlarının zaman serisi tahmininde kullanılabilmesi için ağın mimari yapısının belirlenmesi gerekmektedir. Ağ mimari yapısının belirlenme süreci, ağın kaç katmandan oluşacağını, her katmanda kaç işlem elemanı bulunacağını, bu işlem elemanlarının hangi transfer fonksiyonuna sahip olacağını belirlenmesi gibi işlemleri kapsar. Kaç dönemlik tahmin yapılacağına bağlı olarak çıktı sayısı da belirlenir.

Çok katmanlı yapay sinir ağlarında, danışmanlı öğrenme kuralı uygulanarak ağa bir örnek gösterilir ve örnek neticesinde nasıl bir sonuç üreteceği de bildirilir. Örnekler girdi katmanına uygulanır, ara katmanlarda işlenir ve çıkış katmanından da çıktılar elde edilir.

2.2.7. YSA ile modelleme

Modelin kurulabilmesi için üç temel gereksinim vardır. Bunlar;

- a. Girdi-çıkı verisi,
- b. Modellerin belirlenmesi,
- c. Modelin seçim kriteridir.

Gelecekteki verilerin istatistiksel özelliklerinin geçmiştekilerle uyumlu olacağı varsayımından hareketle, modellemeye konu olan sisteme ait geçmişe dönük verilerin istatistiksel özelliklerinden yararlanılarak kurulan ve zamana bağımlı modele “zaman-serisi modeli” denir. Modelin, geçmişteki verileri yeterli doğrulukta sağlaması kadar gelecekte tekrarlanma ihtimali yüksek özellikleri tanımlaması da gereklidir.

Özellikle, geleceğe dönük kestirim zordur. Sistemin karmaşıklığı ya da hedefin hassaslığına bağlı olarak, tasarlanan modellerin yoğun işlem gerektiren algoritmalarının geçerliliği, gelişen teknolojinin harikası ve vazgeçilmez unsuru bilgisayarların elverdiği kolaylıkla ve hızla sınanabilmektedir. Sınamayı başarıyla geçen modeller öngörü işleminde kullanılmaktadır. Başarılı modellerin sahip olması istenilen diğer özellikler:

- a. Parametre sayısı asgariye indirilmeli,
- b. Parametrelerin kestirimi kolay olmalı,
- c. Parametreler anlamlıca yorumlanabilir olmalarıdır.

2.2.7.1. YSA modelleme faktörleri

YSA ile öngöründe bulunmak için aşağıda belirtilen faktörlerin belirlenmesi gerekmektedir. Her problem için geçerli olacak genel bir YSA modeli belirlenememiştir. Bu nedenle iyi öngörü sonuçları elde edebilmek amacıyla her bir problem için tüm faktörlerin gözden geçirilmesi gerekmektedir.

- a. Verilerin hazırlanması, bir ön işlemden geçirilmesi [(0,1) aralığına normalize edilmesi)],
- b. Eğitim ve test verilerinin ayrıştırılması,
- c. YSA'nın tasarlanması,
Girdilerin belirlenmesi,
Gizli katman sayısının belirlenmesi,
Gizli nöron sayısının belirlenmesi,
Çıktı sayısının belirlenmesi,
- d. Aktivasyon fonksiyonuna karar verilmesi,
- e. Performans ölçütünün hesaplanması,
- f. YSA'nın eğitilmesi,
- g. YSA'nın test edilmesi.

2.2.7.2. Modelleme adımıda yapılacak işlemler

- a. Nöron Sayısı

Girdi nöron sayısını belirlemek için kullanılan genel bir kural yoktur. Deneme-yanılma ile girdi nöron sayısının belirlenmesi sıklıkla kullanılan bir yöntemdir. Bu katmanda nöron sayısı , girdi veri sayısı kadardır ve her bir girdi nöronu bir veri alır. Burada veri, işlenmeden bir sonraki katman olan gizli katmana geçer.

b. Gizli Katman Sayısı

Gizli katman ağın temel işlevini gören katmandır. Bazı uygulamalarda ağda birden fazla gizli katman bulunabilir. Gizli katman sayısı ve katmandaki nöron sayısı, probleme göre değişir. Tamamen ağ tasarımcısının kontrolündedir ve onun tecrübesine bağlıdır.

YSA'da hiç gizli katman bulunmuyorsa ya da girdi katmanındaki birimler ile çıktı katmanındaki birimler arasında doğrusal bağlantı varsa, bu durumda girdilerin bir kısmının çıktılara direkt bağlı olduğu anlaşılır. Hangi girdinin hangi çıktıya bağlı olduğuna göre de bir sonuca varılır. Gizli katman bulunmaması durumunun en klasik örneği, yerine koyma şifrelemesi olarak gösterilebilir. Bu şifreleme yönteminde her harf başka bir harf ile yer değiştirecektir ve her girdi bir çıktıya bağlıdır.

YSA'da tek katman bulunması durumu genelde problemlerin büyük çoğunluğunda karşılaşılan bir durumdur ve kısaca girdi ve çıktı arasında sonlu bir kümeden yine sonlu bir kümeye bağlantı bulunması durumunda kullanılır.

YSA'da birden fazla katmanın kullanılması durumu çok sık rastlanan bir durum değildir. Genelde kesin sonuç beklenmeyen ama bir değere yaklaşması istenen problemlerde kullanılan iki katmanlı çözümler, katman sayısı arttıkça karmaşıklaşmakta ve hem tasarımı hem de analizi zorlaşmaktadır.

c. Gizli Katmandaki Nöron Sayısı

YSA'nın en kritik noktası gizli katmanında kaç nöron olacağına karar vermektir. Chowdary [15], genellikle sonucu direkt olarak vermemesine karşın sonuca direkt etkisi olması açısından gizli katmandaki nöron sayısının oldukça önemli olduğunu belirtmiştir. Çünkü gizli katmanda bulunan nöron sayısı YSA'nın bir süreci modelleme doğruluğunu ve genelleştirme yeteneğini belirlemektedir.

Ayrıca gizli katman nöron sayısı, öğrenme sırasında bellekte fazla bilgi barındırmak haricinde öğrenme işleminin daha iyi yapılmasını da sağlamaktadır.

Çelebi ve diğerleri [16], gizli katmandaki nöron sayısının belirlenmesinde genel bir kuralın bulunmadığına dikkat çekmektedir. Bu nedenle, gizli katman nöron sayısı belirlenirken deneme-yanılma sık kullanılan bir yöntemdir.

Gizli katman; girdi katmanından aldığı ağırlıklandırılmış veriyi probleme uygun bir fonksiyonla işleyerek bir sonraki katmana iletir. Bu katmanda gereğinden az nöron kullanılması, girdi verilerine göre daha az hassas çıktı elde edilmesine sebep olurken, test kümesindeki verilerle doğru sonucu vermemesine sebep olabilir. Normalde iki ayrı nöron üzerinden taşınacak veri tek nöron üzerinden taşınmış olur. Bu da taşınan verinin daha karmaşık olması demektir.

Aynı şekilde gerektiğinden daha çok sayıda nöron kullanılması durumunda da aynı ağda yeni tip veri gruplarının işlenmesinde zorluklar ortaya çıkar ve uyum aşımı olur. Basitçe ifade edilirse, gizli katmanda bulunan her sinir hücresini eğitecek kadar eğitim kümesi bulunmayabilir. Diğer bir problem ise, yeterli miktarda eğitim verisi bulunması durumunda bile karşılaşılabilen geç öğrenmedir. Buna göre sistemdeki bütün sinir hücrelerinin eğitimi normalden çok daha uzun zaman almaktadır.

Gizli katmanda bulunan nöron sayısı YSA'nın bir süreci modelleme doğruluğunu ve genelleştirme yeteneğini belirlediğinden uygun nöron sayısını belirlemek için birçok çalışmada olduğu gibi bu çalışmada da deneme-yanılma metodundan yararlanılmıştır.

d. Çıktı Nöron Sayısı

Çıktı nöron sayısı, zaman serisi tahmin problemlerinde tahmin döneminin uzunluğuna eşit alınabilir. Buna göre çalışmada kaç dönemlik tahmin yapılırsa, çıktı nöron sayısı da o kadar alınabilir. Bu yöntem doğrudan öngörü yöntemidir. Diğer bir yöntem ise iteratif öngörü yöntemi olup, ilk öngörünün veri olarak kullanılıp, bir

sonraki öngörünün elde edilmesi yöntemidir. Hangi öngörü yönteminin daha iyi olduğu konusunda, varılmış genel bir sonuç bulunmamaktadır [17].

e. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu yapay nöron çıktısının büyüklüğünü sınırlandıran fonksiyondur. Aynı zamanda girdi ve çıktı birimleri arasındaki eğrisel eşleşmeyi sağlar. Transfer, eşik ya da sıkıştırma fonksiyonu olarak da isimlendirilmektedir [18]. Seçilen aktivasyon fonksiyonu, doğrusal olmadığında eğitim parametresinin belirlenmesi gerekir [19].

Zaman serileri için sigmoid aktivasyon fonksiyonunun kullanılabileceği, Tebelkis [20]'de belirtilmiştir. Çünkü hem doğrusal olmayan bir fonksiyondur; hem de her yerde türevlenebilirdir. İkili (binary) değişkenler için “adım” fonksiyonu da önerilmektedir.

f. Normalleştirme İşlemi

Sarıtaş [21], girdi ve çıktı verilerinin normalleştirilmesinin, yakınsama ve öğrenme işlemi açısından oldukça önemli olduğunu belirtmiştir. Bu nedenle ağ eğitilmeden önce veriler eğitim karakteristiğini iyileştirmek için kullanılarak (0 – 1) veya (-1 , +1) değerleri arasında normalize edilir;

$$x'_i = \frac{x_i - x_{min}}{x_{maks} - x_{min}} \quad (2.5)$$

$$i = 1, \dots, N$$

Burada,

x_i : N sayıdaki veri kümesinde yer alan i.nci veri,

x_{min} : N sayıdaki veri kümesinde yer alan minimum değere sahip veri,

x_{maks} : N sayıdaki veri kümesinde yer alan maksimum değere sahip veri,

x_i : N sayıdaki veri kümesinde yer alan normalleştirilmiş i.nci veriyi, göstermektedir.

g. Eğitim ve Test Kümesi

Eldeki tüm verilerin ağın eğitimi için kullanılması doğru bir yöntem olmayacaktır. Eğitim, test ve geçerlilik olmak üzere, veri üç gruba ayrılabilir. Bu durumda eğitim kümesi için veri kümesinden daha az bir grupla çalışılacaktır. Bundan kaçınmak için veri kümesi eğitim ve test olmak üzere ikiye de ayrılabilir. Oransal dağılım olarak da % 90 eğitim kümesi ve %10 test kümesi ya da %80 eğitim kümesi ve %20 test kümesi şeklinde bir dağılım kullanılabilir [17].

h. Ağın Eğitimi

YSA'nın en önemli özelliklerinden birisi, ilgili probleme ait örnekler verildiğinde girdiler ile çıktılar arasındaki ilişkiyi öğrenebilmesi; girdi ve çıktı arasında bir eşleştirme yapmasıdır. Ağ yeterince eğitildiğinde daha önceden görmediği girdilere karşı uygun çıktılar üretebilmektedir. Bu özellik YSA'nın genelleme kapasitesi olarak adlandırılır ve çoğunlukla ağın yapısına ve eğitim için uygulanan yineleme sayısına bağlıdır [22].

YSA'da katmanlar arasındaki nöronların bağlantı ağırlık değerlerinin belirlenmesi işlemine “ağın eğitilmesi” denir. Başlangıçta bu ağırlık değerleri rasgele alınır. YSA'lar, kendilerine örnekler gösterildikçe bu ağırlık değerlerini yenileyerek amaca ulaşmaya çalışırlar. Amaca ulaşmanın ya da yaklaşmanın ölçüsü dışarıdan verilen değerdir. Eğer YSA verilen girdi çıktı çiftleriyle amaca ulaşmış ise ağırlık değerleri saklanır. Ağırlık değerlerinin değişmesi belirli kurallara göre yürütülmektedir. Bu kurallara “öğrenme kuralları” denilmektedir. YSA öğrendikten sonra daha önce verilmeyen girdiler uygulanarak ağ çıktıları gözlemlenir.

Bu çalışmada, ileri beslemeli YSA mimarisi göz önüne alınmıştır. Bunun anlamı, nöronlardan çıkan bütün bağlantılar bir sonraki katmandaki nöronlara gitmektedir ve

önceki ya da aynı katmanlar arasında bağlantı mümkün olmamaktadır. Buradaki mimari, çok katmanlı YSA olarak da anılmaktadır. Tipik olarak çok katmanlı, ileri beslemeli YSA, girdi katmanı, gizli katman ve çıktı katmanından oluşmaktadır [1].

Geliştirilen YSA eğitim yöntemi, birden fazla gizli katmana sahip mimariler için de kolaylıkla uygulanabilir. Çözülecek olan problem tipik danışmanlı YSA eğitimidir.

Verilen girdi vektör seti ve onlara karşılık gelen çıktı değerine karşılık, hesaplanan çıktı değerleri ve orijinal çıktı değerlerinin birbirine yaklaşmasını sağlayacak olan nöronlar arası optimum bağlantı ağırlıkları bu yöntemin ulaşmayı hedeflediği problemdir. İterasyonlar arası optimum bağlantı ağırlıkları belirli bir “beklenen çıktı ve hesaplanan çıktı” fark duyarlılığında birbirlerine yaklaştıklarında, YSA’nın öğrendiği sonucuna varılmaktadır.

Yine de, geri yayılım algoritması, uzun eğitim zamanları gerektirmekte, dolayısıyla hızlı eğitim zamanlarına ihtiyaç duyan uygulamalarda çok da uygun bir yöntem olamamaktadır.

Çok katmanlı ve danışmanlı öğrenme, YSA’larda hızlı sonuç verebilecek bir yapıya sahiptir. Böylece problem, kısıtlı doğrusal olmayan optimizasyon problemine dönüştürülmektedir. Kısıtlarda genellikle sigmoid ya da hiperbolik tanjant fonksiyonları kullanılabilir. Hangisinin kullanılacağı, çok katmanlı danışmanlı YSA’nın uygulanmasında kullanılan aktivasyon fonksiyonu ile ilgilidir. Dolayısıyla YSA’da kullanılan aktivasyon fonksiyonu doğrusal olmayan modelde aynen yansımalıdır.

En küçük karelerle yapılmış hata fonksiyonun yerine mutlak hatalar toplam fonksiyonu da kullanılabilir. Mutlak hataların toplam fonksiyonunun amaç fonksiyonu olarak kullanılması, optimum sonucu değiştirmemekle birlikte, amaç fonksiyonunun doğrusal bir forma dönüştürülmesi bakımından bir avantaj olarak görülebilir.


i. Öğrenme Katsayısı (η)

Geri yayılım öğrenme algoritmasında öğrenme katsayısı, ağırlıkların değişim miktarını belirler. Eğer öğrenme katsayısı gereğinden büyük olursa problem uzayında rasgele gezinme olur. Bunun da ağırlıkları rasgele değiştirmekten farkı olmaz. Eğer öğrenme katsayısı çok küçük olursa, çözüme ulaşmak daha uzun sürer. Sabit olarak 1 değerinden çok daha küçük bir değerdir. Başlangıçta büyük η ile başlanır ve dereceli olarak bu değer düşürülür. Ya da küçük η ile başlanılır ve hata artmaya başlayana kadar bu değer büyütülür. Böylece öğrenimin her bir aşamasında maksimum güvenli adım bulunur. Asıl amaç, öğrenme oranı büyürken hatanın minimumda kalmasına çalışılır.

j. Momentum Katsayısı (γ)

Geri yayılım öğrenme algoritmasında öğrenme katsayısı, momentum, öğrenme sürecini hızlandıran alternatif ağırlık ayarlama yöntemidir. Bu yöntemde $t+1$ anındaki ağırlıklar ayarlanırken, t ve $t-1$ anındaki ağırlıkların farkı da hesaba katılır. Momentum katsayısı γ ile gösterilir.


Momentum katsayısı, yerel çözümlere takılmayı önler. γ momentum katsayısı $0 < \gamma < 1$ aralığında seçilir. Momentum kullanıldığında, ağırlıklara göre ardışık iki iterasyonda, aynı işaretli ise ağırlıklara uygulanacak düzeltme artar, aksi taktirde azalır. Momentum katsayısı ile YSA'nın öğrenme oranında belirli bir hızlanma elde edilir. Bu değer çok küçük seçilmesi yerel çözümlerden kurtulmayı zorlaştırır. Değerin çok büyük seçilmesi ise tek bir çözüme ulaşmada sorunlar yaratabilir. Algoritma dengede iken momentum kullanarak daha büyük bir öğrenme hızı elde edilebilir. Momentumun diğer bir özelliği ise yörünge tutarlı bir yönde hareket ettiğinde yakınsamanın hızlanmasıdır. Hata belli bir eşiğin altında artmışsa momentum değeri değiştirilmez. Ağ parametrelerinin güncellenmesi iptal edilir. Hata azalıyorsa parametre güncellemesi yapılır. Öğrenme hızı ve momentum değeri bir miktar artırılır. Momentum değerindeki değişime göre ağırlıkların değişim miktarı Şekil 2.6.'da gösterilmiştir.



Şekil 2.6. Momentum değeriindeki değişime göre ağırlıkların değişim miktarı [13].

k. Eğitimin Durdurulması

Hatanın belli bir değerin altına düşmesi sonucunda eğitim sonlandırılır ya da belirli sayıda iterasyondan sonra eğitim durdurulur. Her iki yönteminde dezavantajları olabilir. Örneğin başta belirlenen iterasyon sayısı yüksek ise ağ hatayı minimize etse dahi boşuna öğrenmeye çalışmaya devam eder. Diğer durumdaki dezavantaj ise; ağın gereğinden fazla eğitilmesiyle, problemi öğrenmek yerine verileri ezberlemeye başlamasıdır. Bu da ağın hatalı sonuçlar üretmesine neden olur. Şekil 2.7.'de eğitimin durdurulması için hata ve iterasyon sayısı gösterilmiştir. Çalışmamızın uygulama aşamasında, her veri kümesi için kullanıcı tarafından belirlenmiş bir hata değerine ulaşılması sonucu eğitim durdurulmuştur.



Şekil 2.7. Eğitimin durdurulması için hata ve iterasyon değerleri [13].

1. Ağın Test Edilmesi

Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini test etmek amacıyla yapılan denemeler ağın test edilmesi aşamasını oluşturmaktadır. Öztemel [1], test aşamasında ağa öğrenme aşamasında görmediği verilerin uygulanması gerektiği belirtmiştir. Bu işlem test kümesindeki verilerin kullanılması ile gerçekleşmektedir.

m. Performans Ölçütleri

En iyi YSA mimarisinin belirlenmesinde çeşitli performans ölçütlerinden yararlanılır [19]. YSA'da genellikle Hata Kareler Ortalaması performans ölçütü olarak tercih edilir. HKO aşağıda belirtildiği gibi hesaplanır;

$$H.K.O. = \sum_{i=1}^N \frac{(e(n))^2}{N} \quad (2.6)$$

Burada;

N : test kümesi veri sayısı,

e(n) : orijinal değer ile tahmin edilen değer arasındaki farktır.

Diğer performans ölçütleri ise (2.7) ile (2.10) arasındaki eşitliklerde verilmiştir.

$$\text{Ortalama Mutlak Hata (OMH)} = \sum_{i=1}^N \frac{|e(n)|}{N} \quad (2.7)$$

$$\text{Ortalama Mutlak Yüzde Hata (OMYH)} = \left(\frac{1}{N}\right) \sum_{i=1}^N \left| \frac{e(n)}{y(n)} \right| (100) \quad (2.8)$$

$$\text{Hata Kareler Toplamı (HKT)} = \sum_{i=1}^N (e(n))^2 \quad (2.9)$$

$$\text{Hata Kareler Ortalaması Karekökü (HKOK)} = \sqrt{HKO} \quad (2.10)$$

Burada;

N : test kümesi veri sayısı,

e(n) : orijinal değer ile tahmin edilen değer arasındaki fark,

y(n) : orijinal değer,

HKO. : hata kareler ortalamasıdır.

2.3. ANFIS Bulanık Çıkarım Sistemi

Bilimsel çalışmalarda üzerinde çalışılan olaylar ve sistemler matematiksel modellerle tanımlanmaktadır. Oluşturulan matematiksel modeller, o olayın veya sistemin gelecekte alacağı durum ve göstereceği davranış biçimini de ortaya konmasını sağlamaktadır [23]. Fakat günlük yaşantımızda karşı karşıya kalınan problemlerin birçoğu çeşitli sebeplerden dolayı modellenememekte ya da kesin bir durumu ifade etmekte yetersiz kalmaktadır. İşte karşı karşıya kaldığımız bu tip problemlerin incelenmesinde ve çözümlenmesinde “Bulanık Mantık Yaklaşımı” kullanılabilmektedir [24,25].


Bulanık mantığın temeli, sözel ifadeler ve bunlar arasındaki mantıksal ilişkiler üzerine oluşturulmuştur. Sözel ifadeler aslında matematiksel bir temele dayandırılmıştır. Bu matematiksel temel, bulanık küme teorisi ve bulanık mantık olarak ifade edilmektedir. Bulanık mantık, bilinen klasik mantığın aksine 0 veya 1 olmak üzere iki seviyeli değil, [0,1] aralığında çok seviyeli işlemlerin ifadesinde kullanılmıştır [25, 26].

Bulanık mantık ile modelleme üç aşamadan oluşmaktadır. Bunlar: bulanıklaştırma, bulanık kural çıkarma ve durulama olarak isimlendirilmektedir. Bulanıklaştırma aşamasında, sistem girişlerinin üyelik fonksiyonları oluşturularak, uygun bulanık kümeler üyeli dereceleri belirlenmektedir. Bulanık kural çıkarma aşaması, üyelik fonksiyonlarını ve “eğer-öyleyse” kurallarını kullanarak, bulanık kümenin diğeriyle

ilişkilendirilmesinden oluşmaktadır. Durulama aşaması ise bulanık çıkış değerinin, bir kesin çıkış değerine dönüştürülmesini ifade etmektedir [27].

2.3.1. ANFIS bulanık çıkarım sistemi yapısı

Bulanık sistemler, genel anlamda, giriş değişkenlerinden çıkış değişkenlerini elde etmek amacıyla bulanık kümeleri kullanmaktadır. Bulanık çıkarım sistemlerinde kural tabanında kullanılan bulanık kuralların sonuç kısımları yardımıyla Bulanık Sistemleri; Mamdani ve Takagi-Sugeno-Kang olmak üzere ikiye ayırabiliriz. Sugeno tipi modelleme 1985 yılında kullanılmıştır. Mamdani tipi modellemenin uyarlaması şeklindedir ve giriş verilerine uygulanacak işlemler aynıdır. Tek farklılıkları çıktı verilerinden oluşmaktadır. Sugeno tipi modellemede çıktı değişkenleri girdilerin bir fonksiyonu şeklinde üyelik fonksiyonlarına sahip olmaktadır ve çıktı üyelik fonksiyonları doğrusal veya sabit olmalıdır [28]. 1993 yılında Jang tarafından geliştirilen ve parametreleri optimize edilerek kullanılan Sugeno tipi bulanık çıkarım sistemlerine, Adaptif Sinir Ağına Dayalı Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System-ANFIS) denilmektedir [28]. Aslında ANFIS, Sugeno tipi bulanık sistemlerin, sinirsel öğrenme yeteneğine sahip bir ağ yapısı temsiliinden oluşmaktadır. Bu ağ, her biri belli bir fonksiyonu gerçekleştirmek üzere, katmanlar halinde yerleştirilmiş düğümlerin birleşiminden meydana gelmiştir [29,30]. Aşağıdaki Şekil 2.8.'de iki giriş, iki kural, tek çıkışlı Sugeno Bulanık çıkarımına eşdeğer ANFIS mimarisi verilmiştir. ANFIS , 5 tabakalı ileri beslemeli bir yapay sinir ağı yapısına sahiptir. Bu tabakaların görevleri şu şekilde özetlenebilir [31, 32].



Şekil 2.8. İki girişli- tek çıkışlı birinci dereceden kural polinomlu ANFIS mimarisi [23].

1. Tabaka: Girdi değişkenlerinin her biri adaptif bir bağlantı ucu (node) oluşturur, yani, node sayısı girdi değişkeni sayısına eşittir. Bu değişkenlerin üyelik fonksiyonları node fonksiyonu olarak kullanılır. Bu üyelik fonksiyonlarının parametreleri “öncül parametreler” olarak adlandırılır.

2. Tabaka: Nodlar sabit karakterdedir. Node sayısı kural sayısına eşittir. Node girdileri, kuralların öncül kısmındaki değişkenlerin üyelik fonksiyon değerleri, node çıktıları ise, kuralların ağırlık dereceleri (firing strength) dir.

3. Tabaka: Node girdileri, kuralların ağırlık dereceleri, çıktıları ise, normalize edilmiş ağırlık dereceleridir. Yani bu tabakanın görevi, kuralların ağırlıklarını normalize etmektir.

4. Tabaka: Bu tabakadaki nodlar adaptifdir. Node fonksiyonu, Sugeno Sistemi’nde, herhangi bir mertebeden (çoğunlukla 1. mertebe) bir fonksiyondur. Model parametreleri, “berraklaştırma” veya “sonuç parametreleri” olarak adlandırılır.

5. Tabaka: Tek noddan ibaret olan bu tabakanın çıktısı, crisp karakterde model çıktısıdır.

Bu yapının parametreleri; öncül ve sonuç parametreleridir. Eğitim veri seti, bu yapay sinir ağına tanıtılır ve herhangi bir eğitime algoritması vasıtasıyla, eğitim veri setinde girdi-çıkı fonksiyonel ilişkisini en iyi şekilde öğrenir. Aslında bu işlem bir optimizasyon işleminden başka bir şey değildir. Model çıktısı ile eğitim veri seti çıktısı (ölçüm, deneysel sonuç vs.) arasındaki farkın kareler toplamı şeklinde ifade edilen hata fonksiyonunun minimum olduğu şartların bulunması, yani, parametrelerin optimum değerlerinin tespiti hedeflenir [33].

2.3.2. ANFIS ağında kullanılan hibrid öğrenme algoritması

Kimliklendirmede kullanılan ANFIS ağına ait parametrelerin güncellenmesinde, iki aşamalı bir öğrenme algoritması olan, hibrid öğrenme algoritması kullanılmıştır. Hibrid öğrenme algoritmasında, ANFIS ağ yapısına ait parametreler, giriş ve çıkış parametreleri olarak iki kısımda ele alınır. Toplam parametre kümesi; $S = S_1 + S_2$ şeklinde ifade edilecek olursa, S_1 giriş parametrelerine, S_2 de çıkış parametrelerine karşılık gelir. Hibrid algoritmanın ilk aşaması yada ileri yön geçişi ile ANFIS ağına ait giriş parametreleri, ikinci aşamada yada geri yön geçişinde ise ağın sonuç parametreleri güncellenir. Hibrid öğrenme algoritmasının ileri yön geçişini oluşturan ve en küçük kareler tahmini (LSE) yöntemi kullanılmak suretiyle gerçekleştirilen kısmında, ağın girişindeki üyelik fonksiyonlarına ait parametreler yada kısaca S_1 ile belirtilen giriş parametreleri sabit tutulur. Böylece ağın çıkışı, S_2 parametre kümesi içinde bulunan çıkış parametrelerinin, lineer bir kombinasyonu haline gelir. Modellenecek sisteme ait P tane giriş-çıkış verisi yada eğitim datası ile S_1 giriş parametrelerinin verilen değerleri kullanılarak, ağın çıkışı, matrisel formda;

$$A\theta = B \quad (2.11)$$

şeklinde ifade edilebilir. Matrisel eşitlikte yer alan θ vektörü, S_2 çıkış parametrelerinin elemanlarından oluşan, bilinmeyen vektördür. Bu denklem, standart lineer en küçük-kareler (least-squares) problemini gösterir ve θ için en iyi çözüm, $\|\theta A - B\|_2$ nın minimum değeri olan, en küçük kareler tahmini (LSE) θ^* dır;

$$\theta^* = (A^T A)^{-1} A^T B \quad (2.12)$$

Burada A^T , A matrisinin transpozu ise ve eğer $A^T A$ singular değilse, $(A^T A)^{-1} A^T$, A'nın sahte inversidir. Özel olarak A matrisinin i. satırı a_i^T ile B matrisinin i. elemanı b_i^T ile gösterilsin. Bu taktirde θ vektörü, iteratif olarak aşağıdaki gibi hesaplanabilir;

$$\theta_{i+1} = \theta_i + S_{i+1} a_{i+1} (b_{i+1}^T - a_{i+1}^T \theta_i) \quad (2.13)$$

$$S_{i+1} = S_i - \frac{S_i a_{i+1} a_{i+1}^T S_i}{1 + a_{i+1}^T S_i a_{i+1}}, \quad i = 0, 1, \dots, P-1 \quad (2.14)$$

İhtiyaç duyulan başlangıç şartları şunlardır; $\theta_0 = 0$ ve $S_0 = \gamma I$. Burada γ , pozitif büyük bir sayı, I ise MxM boyutunda birim matristir.

Hibrid öğrenme algoritmasının geri yön geçişinde, S_2 çıkış parametreleri sabit tutulur ve ağıın çıkışındaki hata sinyali geriye doğru yayılarak, eğim düşümü (gradient descent) yöntemiyle giriş parametreleri güncellenir. Geri yön geçişinde giriş parametreleri için güncelleme formülü aşağıdaki gibidir;

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

Burada α herhangi bir giriş parametresini, η öğrenme oranını, E ise ağıın çıkışındaki hata değerini göstermektedir [34].

2.3.3. Bulanık mantığın kullanıldığı bazı uygulamalar

- a. Hidroelektrik güç üniteleri için kullanılan baraj kapılarının otomatik kontrolü (Tokio Electric Pow.)
- b. Stok kontrol değerlendirmesi için bir uzman sistem (Yamaichi, Hitachi)
- c. Klima sistemlerinde istenmeyen ısı iniş çıkışlarının önlenmesi
- d. Araba motorlarının etkili ve kararlı kontrolü (Nissan)
- e. Otomobiller için “Cruise-control” (Nissan, Subaru)
- f. Dökümanların arşivleme sistemi (Mitsubishi Elec.)
- g. Depremlerin önceden bilinmesi için tahmin sistemi (Inst. of Seismology Bureau of Metrology, Japan)
- h. İlaç teknolojileri: Kanseri teşhisi (Kawasaki Medical School)
- i. Cep bilgisayarlarında el yazısı algılama teknolojisi (Sony)
- j. Video kameralarda hareketin algılanması (Canon, Minolta)
- k. El yazısı ve ses tanımlama (Hitachi, Hosai Univ., Ricoh)
- l. Helikopterler için uçuş desteği (Sugeno)
- m. Çelik sanayinde makina hızı ve ısısının kontrolü (Kawasaki Steel, New-Nippon Steel)
- n. Raylı metro sistemlerinde sürüş rahatlığı, duruş mesafesinin kesinliğini ve ekonomikliğin geliştirilmesi (Hitachi)
- o. Otomobiller için gelişmiş yakıt tüketimi (Nippon Denki Tools)

BÖLÜM 3. JEOFİZİK KUYU LOGLARI

Kömür ve diğer madenlerin (petrol vb.) aranmasında uygulanan jeofizik yöntemler iki ana grupta toplanmaktadır:

- a. Yüzey jeofiziği
- b. Kuyu logları.

Yüzey jeofiziğinden kasıt, topoğrafik yüzey üzerinde gezdirilen değişik cihazlarla, yerkabuğunun birkaç km kalınlıktaki en üst kesimini oluşturan kaya toplulukları ile ilgili bazı fiziksel değerlerin (kayaların yoğunluğu, elektrik iletkenliği, sismik hız gibi) elde edilmesi ve bunlardan yararlanarak yeraltı jeolojisinin aydınlığa kavuşturulmasıdır. Kömür aramacılığında uygulanan başlıca yüzeysel jeofizik yöntemler gravite, rezistivite ve sismik refleksiyon şeklinde sıralanabilir.

Kuyu logları ise, açılmış sondaj kuyularına sarkıtılan değişik log aletleriyle, sondajda kesilen kaya toplulukları ile ilgili jeofizik değerlerin elde edilmesini sağlayan yöntemlerdir.

3.1. Kuyu Logları

Sondajlarda kesilen birimlerin yada seviyelerin bazı fiziksel özelliklerini saptamak ve bu seviyelerde bulunabilen su, petrol ve gaz gibi akışkanlar hakkında bilgi sağlamak için kuyu içine indirilen ve log aleti adı verilen özel cihazlarla kayıt alma işlemine kuyu logu alımı(well-logging) denir.


İlk kuyu logu alımına 1926 yılında ABD'de Conrad ve Marcel Schlumberger kardeşler tarafından, petrol sondajlarında başlanmış ve bu uygulamalar kısa bir sürede hızla yayılmıştır [35]. Başlangıçta yalnızca rezistivite ölçümleri şeklindeki log

alımları giderek çeşitlenmiş, ayrıca petrol dışında, kömür diğer enerji kaynakları, metalik madenler ve endüstriyel hammadde aramalarında geniş uygulama alanı bulmuştur [36].

Günümüzdeki uygulamalarda, aranan madenin türüne göre 30'dan fazla log çeşidi bulunmaktadır. Aşağıda bunlardan yalnızca kömür ve benzeri katı yakıtlarla ilgili olarak açılan sondaj kuyularında alınan loglardan söz edilecektir. Bunlar;

- a. SP,
- b. Rezistivite,
- c. Gamma-ray,
- d. Gamma-gamma(yoğunluk logu veya density log),
- e. Sonik,
- f. Nötron logları şeklinde sıralanabilir.

Kuyularda log alımı genellikle servis şirketleri tarafından yapılmaktadır. İşlem bir log kamyonu ile yapılmaktadır. Açılan kuyulardan bilgi toplamak için yerüstündeki ortamı kule ve log kamyonu, yeraltındaki ortamı kuyu ve formasyon oluşturur. Bu ortamlar Şekil 3.1.'de gösterilmiştir. Yeraltındaki ortamlardan bilgi toplamak için log kablosuna bağlanan log aleti kuyuya sarkıtılır. Genel olarak, kuyu dibinden başlayıp, kayıt yapılarak, alet yukarı çekilir. Elde edilen veriler log kağıdına, saydam filmlere, kaset, disk veya disketlere kaydedilir. Kablo çekilirken kablodaki gerilimi kontrol etmek için üst makaraya bir ağırlık ölçer takılır. Log aletleri genel olarak borulanmamış kuyularda (açık kuyularda) ve borulanmış kuyularda çalışan aletler olarak iki sınıfa ayrılırlar. Her iki sınıfa da girebilen log aletinin sayısı azdır. Hem borulanmış hem açık (borulanmamış) kuyuda çalışan aletler, genel olarak formasyondan doğal olarak gelen sinyallerle çalışan log aletleridir. Örneğin, doğal radyoaktif ışımayı ölçen Gamma Ray veya doğal sıcaklığı ölçen Temperature Log aletleri gibi. Ama log aletleri genellikle kendi yarattıkları sinyalleri formasyona gönderip, geri gelen sinyallerdeki değişimleri formasyonların özellikleri olarak kaydederler [37].



Şekil 3.1. Log kaydı için yerüstü ve yeraltındaki ortamlar [37].

Log aleti çapı 4 - 9 cm, boyu ise genelde 40 - 400 cm arasında değişen silindirik biçimli bir cihazdır. Çelik kablo ucunda kuyu dibine kadar, yada istenilen seviyeye kadar indirilir ve sonra geri çekilir. İniş yada çıkış sırasında kayıt yapılır. Uygulanacak yönteme göre (rezistivite, gamma-ray vb.) çeşitli log aletleri geliştirilmiştir.

Kuyu logu, kuyu veya kuyuyu çevreleyen formasyonların bazı özelliklerini (yoğunluk, kalınlık, eğim, yön, gözeneklilik, geçirgenlik, su veya petrolle doygunluğu, litolojisi vs...) gösteren bir kayıttır. Modern log tekniği, kuyuda akla gelebilecek her türlü fiziksel veya kimyasal özelliğin ölçülmesini sağlamaktadır.

3.2. Uygun Log Ortamları

Bir log aletinin verimli biçimde çalışması için ortamın log alımına uygun olması gerekir. Log alımından önce aşağıdaki koşulların uygunluğu öncelikle araştırılmalıdır;

- a. Derinlik, basınç ve sıcaklık
- b. Kuyu çapı
- c. Sondaj çamuru
- d. Yönlü kuyular

Log aletleri genellikle 20000 psi basınç, 350°F sıcaklıkta çalışabilecek şekilde yapılmışlardır. Daha yüksek basınç ve sıcaklık değerleri için özel log aletleri vardır.

Doğru bir log alımı için en fazla kuyu çapını belirlemek zordur: Kuyu çeperine değmesi gereken Density, Neutron, MSFL ve Dipmeter gibi aletlerin ayakları arasındaki açıklık 16 - 22 inç civarındadır. Bu nedenle, bu aletler için en fazla açıklığı kuyu çapı belirler. Doğru log alımı için kuyu çapı en fazla 12 inç civarında olmalıdır [37].

Sondaj çamurunun tipi en çok rezistivite logları için önemlidir. Petrollü veya rezistivitesi çok yüksek çamurlu kuyularda Dual Induction, tuzlu çamurlu veya rezistivitesi düşük çamurlu kuyularda Dual Laterolog aletleriyle rezistivite ölçülebilir.

Barit ve hematit gibi çamuru ağırlaştırıcı maddeler Density aletinin Correction eğrisini etkiler. Ayrıca bu maddeler yönlü kuyuda kuyunun alt kenarına birikerek loglara etki ederler. KCI (potasyum klorür) radyoaktif bir malzeme olup, çamura katıldığında GR log değerini arttırıcı rol oynar.


Düşey olmayan kuyulara yönlü kuyular denilir. Yönlü kuyularda kuyu ekseninin düşey doğrultuyla yaptığı açıya sapma açısı denilir. Sapma açısı 90 derece veya 90

dereceye yakın olan kuyular yatay kuyulardır. Bir kuyuda 40 derecelik bir sapma açısı log aletlerinin kuyuya indirilmesini genel olarak engellemez.

3.3. Kömür Aramalarında Kullanılan Kuyu Logu Ölçüleri

3.3.1. SP logu

Kuyu ve formasyon içindeki iyon hareketlerinin potansiyel doğurduğu ilk defa 1920'li yıllarda fark edildi. O zamandan bu yana kuyuya indirilen bir elektrotla ölçülen potansiyel Spontaneous Potential (SP) Logu olarak anıldı. Bir elektrot kuyu içinde şeyl boyunca hareket ettiği sürece, SP eğrisi düzdür. Elektrot geçirimli bir tabakaya rastladığında SP eğrisi incelendiğinde geçirimli tabakalar kolaylıkla ayırt edilebilir. Elektriksel potansiyelin iki elektrot arasında ölçülmesi gerektiğinden, bir ucunda kuyuya indirilen elektrot bulunan yalıtkan bir kablonun diğer ucu yeryüzünde toprağa gömülüdür. Bu düzenek SP aletini oluşturur (Şekil 3.2.).



Şekil 3.2. Yeryüzünde SP gerilimi oluşmasıyla, yerüstündeki elektrokimyasal bir pil geriliminin oluşması arasındaki benzerlik [37].

3.3.2. Rezistivite logu

Kayaların rezistiviteleri, kayanın türüne, kapsadığı kil ve akışkan (tatlı su, tuzlu su, petrol, doğal gaz gibi) miktarına bağlı olarak genellikle 0,2 – 1000 Ωm arasında


değişir. Sondajlarda sık rastlanan bazı sedimanter kayalara ait rezistivite değerleri şöyledir [35];

- | | |
|------------------------------|-----------------------------|
| a. Kıltaşı | : 2 - 10 Ωm |
| b. Tuzlu su kapsayan kumtaşı | : 0,5 - 10 Ωm |
| c. Petrollü kumtaşı | : 5 - 1000 Ωm |
| d. Kireçtaşı | : > 1000 Ωm |
| e. Linyit | : > 100 Ωm |

Genelde kayaçların rezistiviteleri yüksek, yani iletkenlikleri düşüktür.

Kömürün rezistivitesi de genellikle yüksektir. Gözenekliliği arttıkça rezistivitesi düşer. Ayrıca kil ve nem yüzdesi arttıkça da rezistivitesi azalmaktadır. Kömürün gözenekliliği, kömürleşme derecesi (rank) ile bağlantılı olduğundan, linyitten antrasite doğru gidildiğinde rezistivite değerleri artmaktadır.

Kuyularda rezistivite logu alımları 1926 yılında Schlumberger firması tarafından başlatılmıştır. Elektrotların dizilimine bağlı olarak normal ve yanal (lateral) olmak üzere iki çeşit rezistivite logu mevcuttur. Normal logun çalışma prensibi Şekil 3.3.'te görülmektedir.




Şekil 3.3. Normal log şeması [35].

Kuyuda, sondaj çamuru içindeki A noktasından elektrik akımı verilir ve M ile N noktalar arasındaki potansiyel farkı ölçülür. Kuyu içindeki çamur iletkenliği sağlamaktadır.

M ile A noktaları arası mesafe ya 0,40 m (16") yada 1,60 m (64") olmaktadır.

Yanal logun şeması Şekil 3.4.'teki gibidir. Ölçüm elektrotları M ve N birbirine yakındır. Burada da yine A noktasından akım gönderilir ve M ile N arasında potansiyel farkı ölçülür.




Şekil 3.4. Yanal log şeması [35].

Nem oranı yüksek linyitler dışında kalan diğer kömürlerin rezistiviteleri genelde yüksektir. Ancak kumtaşı ve kireçtaşlarının rezistiviteleri de yüksek olduğundan bazı sahalarda rezistivite logları üzerinde kumtaşı, kireçtaşı ile kömürü ayırt etmek olanaksız hale gelmektedir. Bu gibi sahalarda rezistivite yanında başka logların alınması gerekir.

Şeyl- çamurtaşı gibi killi çökeller arasında bulunan kömür seviyeleri ise rezistivite logları üzerinde kolayca ayırt edilebilmektedir. Çünkü killi çökellerin rezistiviteleri kömürlere oranla çok düşüktür.

Şekil 3.5.'de kumtaşı, şeyl ve kömür ardalanmasından oluşan bir istifte açılan sondaj kuyusunda alınmış rezistivite logu ile birlikte diğer loglar görülmektedir. En yüksek rezistivite değerlerinin kömür seviyelerine karşılık geldiği dikkati çekmektedir.

Rezistivite logları su veya sondaj çamuru ile dolu çıplak kuyularda, yani muhafaza borusu indirilmemiş kuyularda alınabilir. İçinde akışkan bulunmayan borulanmış kuyularda ise alınamaz.



Şekil 3.5. Kumtaşı, şeyl ve kömür ardalanmasından oluşan bir çökel topluluğunu kesen sondaj kuyusunda alınmış log örnekleri [38].

3.3.3. Gamma-ray logu

İlk nükleer kuyu logudur. Uygulanmasına 1930'lu yılların sonlarında başlanılmıştır.


Sedimanter kayalar içinde bulunan ^{40}K , U, Th gibi radyoaktif elementler tarafından yayılan doğal radyasyonun ölçümüne dayalı bir yöntemdir. Bu elementler sürekli gamma ışınları yayar. Yayılan gamma ışınları kuyu içindeki sondaj çamuruna

geçmekte; ölçümler kuyuya indirilen ve doğal gamma algılayıcısı olan bir log aleti ile yapılmaktadır.

Yukarıda adı geçen radyoaktif elementler en çok şeyl, çamurtaşı gibi killi kayalar içinde bulunur. Dolayısıyla killi kayaların radyoaktiviteleri yüksektir. Buna karşılık kömür, kireçtaşı, dolomit, kumtaşı, anhidrit, kaya tuzu gibi sedimanter kayaların radyoaktiviteleri düşüktür. Killi kömürlerin radyoaktiviteleri ise oldukça yüksektir.

Şekil 3.6.'da bazı sedimanter kayaların radyoaktif madde tenörlerinin dağılımı görülmektedir [35]. Kayaların radyoaktif madde tenörleri, ya Şekil 3.6.'daki gibi $\mu\text{g}/\text{Ra}/\text{ton}$ kaya olarak, ya da API birimi (*API unit*) şeklinde ifade edilir.

Bir formasyon ya da seviyenin birden fazla radyoaktif element kapsamı durumunda gamma- ray loguna yansıyan radyoaktivite değeri çok daha yüksek olmaktadır.



Şekil 3.6. Bazı sedimanter kayaların radyoaktif madde içerikleri [35].

Yukarıdaki açıklamalardan da anlaşılacağı gibi, gamma-ray loglarından esas olarak;

- Killi seviyelerin saptanmasında,
- U, Th, K gibi elementlerin yoğunlaştığı düzeylerin belirlenmesinde yararlanılmaktadır.

Ayrıca gamma-ray logları ile kömür gibi çok az radyoaktif olan enerji kaynaklarının saptanması da olanaklıdır. Kömür (linyit, taşkömürü, antrasit) gamma-ray logu üzerinde çok düşük radyoaktivite değerleri gösterir. Herhangi bir kömür seviyesinin altında veya üstünde yer alan kayaların (kumtaşı, silttaşı, çamurtaşı gibi) radyoaktiviteleri genel olarak daha yüksektir. Buna karşılık bitümlü şistler esas olarak killi çökeller (şeyl veya çamurtaşı) oldukları için radyoaktiviteleri yüksektir. Bu özelliklerinden dolayı kömürden ayırt edilmeleri olanaklıdır. Ancak bu kayaların içindeki organik madde (kerojen) oranı arttıkça radyoaktiviteleri azalır.


Bazı sedimanter havzalarda kumtaşı ve kireçtaşlarının radyoaktivite değerleri kömürlerinki kadar düşük olabilmekte, dolayısıyla gamma ray logu üzerinde bir kömür seviyesini, kumtaşı ve kireçtaşı seviyesinden ayırt etmek olanaksız hale gelmektedir. Böyle durumlarda gamma-ray loguna ilave olarak, örneğin yoğunluk logu (gamma-gamma) alınması gerekir. Çünkü kömürün yoğunluğu diğer kayalara oranla çok düşüktür.

Genelde kömürlerin uranyum içerikleri düşüktür. Ancak bazı sahalarda uranyum tenörü yüksek kömür seviyelerine rastlanabilmektedir. Bu tür kömürler gamma-ray logunda yüksek radyoaktivite değerleri gösterir.

3.3.4. Gamma-gamma logu


Yoğunluk logu (density log) olarak da adlandırılır.

Bu logda, log aletinin bir noktasından çevreye yapay gamma ışını gönderilmekte, bir başka noktasında ise, kayaların içinden geçerek tekrar log aletine gelen ışın miktarı ölçülmektedir (Şekil 3.7.). Genellikle gönderilen ışın ^{60}Co veya ^{137}Cs ' dir. Bu ışın, kayayı oluşturan atomların elektronları ile çarpışır. Elektron sayısı, kayanın yoğunluğu ile orantılı olduğundan, yoğunluk ne kadar fazla ise çarpışma miktarı o kadar fazla, dolayısıyla log aletinin alıcısına gelen ışın miktarı o kadar az olmaktadır.



Şekil 3.7. Gamma-gamma log aleti ve gamma ışınlarının izlediği yolu gösteren şema [35].

Şekil 3.8.'de kaya yoğunluğu ile log aleti alıcısına gelen gamma-gamma değeri (saniyede darbe sayısı olarak) arasındaki bağlantı gösterilmiştir.



Şekil 3.8. Kaya yoğunluğu ile log aleti alıcısındaki c.p.s. (saniyede darbe sayısı) arasındaki ilişki [35].

Grafikte görüldüğü gibi, alıcıda kaydedilen saniyede darbe sayısı (c.p.s.) azaldıkça kayacın yoğunluğu artmaktadır. Bu da bize gamma-gamma logu ile yeraltında kömürlü seviyelerin saptanabileceğini göstermektedir. Çünkü kömürlerin (linyit, taşkömürü, antrasit) yoğunlukları $1,1 - 1,8 \text{ g/cm}^3$ arasında değişirken, bir kömür seviyesinin altında veya üstünde bulunan kömürsüz diğer sedimanter kayaların (şeyl, kumtaşı, kireçtaşı vb.) yoğunlukları $1,2 - 2,9 \text{ g/cm}^3$ arasında değişmekte olup ortalaması ise $2,5 \text{ g/cm}^3$ 'tür (Tablo 3.1.).

Tablo 3.1. Kömür ve bazı minerallerin yoğunlukları (g/cm^3) [35].

Anhidrit	2,95
Dolomit	2,85
Kalsit	2,71
Kuvars	2,66
Kaolinit	2,63
İllit	2,76
Montmorillonit	2,7
Kömür	1,1-1,8

Tablo 3.2.'de kömürün ve diğer bazı kayaların gamma ve gamma-gamma loglarına yansıyan özellikleri görülmektedir.

Tablo 3.2. Kömür ve diğer bazı kayaların gamma ve gamma-gamma loglarına yansıyan özellikleri [38].

Kaya Türü	Gamma-Ray	Gamma-Gamma (Density)	
		g/cm^3	Saniyede Darbe Sayısı
Kömür	Düşük	Düşük	Yüksek
Şeyl	Yüksek	Yüksek	Düşük
Kumtaşı	Düşük	Yüksek	Düşük
Kömür içinde FeS_2	Düşük	Yüksek	Düşük


Gamma-gamma log aletlerinde gamma ışını yayan verici ile bu ışınları algılayan alıcı arasındaki mesafe alet tipine göre 48 cm, 23 cm veya 15 cm olabilmektedir. Bu mesafenin 48 cm olduğu log aletlerine LSD (*Long Spacing Density*), 23 cm olduğu log aletlerine HRD (*High Resolution Density*) ve 15 cm olanlara da BRD (*Bed Resolution Density*) adı verilmektedir.

LSD log aletleri, kaya yoğunluk ölçümleri için en uygun olanlardır. HRD ve BRD log aletleri ise litolojik sınırların ve ince katmanların saptanmasında kullanılan log aletleridir.

Şekil 3.5.'te, kömür kesen bir sondajda alınmış rezistivite, LSD vb. loglar görülmektedir. LSD logu ile ilgili değer g/cm^3 (yoğunluk) olarak verilmiştir. Bu logda kömür seviyeleri net bir biçimde ayırt edilebilmektedir.

Şekil 3.9.'da yine kömürlü bir sahadaki sondaj kuyusunda alınmış gamma-gamma (BRD, LSD) ve kaliper (*caliper*) logları görülmektedir [38].


Gamma-gamma loglarında değerler saniyede darbe sayısı (c.p.s.) olarak verilmiştir, c.p.s. değerleri kömür seviyeleri karşısında yüksek, kumtaşı, şeyl gibi diğer seviyeler karşısında ise düşüktür. Gamma-gamma logu üzerinde, saniyede darbe sayısı arttıkça gözeneklilik de artmaktadır.



Şekil 3.9. Kömürlü bir istife ait BRD, LSD ve kaliper logu örnekleri [38].


Gamma-gamma logu ile kömürün kalitesi, örneğin kül oranı hakkında da bilgi elde edilebilmektedir. Kül oranı ile gamma-gamma logunda (HRD) saniyede darbe sayısı (c.p.s.) arasında şekil 3.10.'da görülen doğrusal bir bağlantı söz konusudur. Kömürün

kül oranı arttıkça c.p.s. değeri azalmakta, kül oranı azaldıkça c.p.s. değeri artmaktadır [38].



Şekil 3.10. Kömürün kül oranı ile HRD logu c.p.s. değerleri arasındaki ilişki [38].

Şekil 3.11.'de bir kuyudaki kömür seviyesine ait LSD logu ve bu log üzerinde hesaplanmış kül yüzdeleri ile aynı seviyeye ait kömür karotları üzerinde laboratuvarlarda yapılan analizlerle belirlenmiş kül yüzdeleri görülmektedir. Her iki yöntemle saptanan kül yüzdeleri arasında büyük bir benzerlik söz konusudur.



Şekil 3.11. Bir kömür seviyesine ait LSD logu (gamma-gamma) ile belirlenmiş kül yüzdeleri ile kömür karotları üzerinde ölçülmüş kül yüzdelerinin kıyaslanması [38].

Sonuç olarak gamma-gamma logu (*density log*) ile sedimanter kayaların yoğunluklarını ve dolayısıyla yoğunluğu düşük olduğu için kömür seviyelerini ve

bunların kalınlıklarını saptamak, ayrıca kayaların birincil gözenekliliklerini, kömürlerin kül oranlarını belirlemek olanaklıdır.

3.3.5. Sonik log


Sonik loglara akustik log adı da verilir.

Yeraltındaki kayaların ses dalgalarını iletme yeteneklerine dayalı bir yöntemdir. Bu loglardan, kaya türlerinin ve bunların gözenekliliklerinin belirlenmesinde yararlanılır.

Sonik log alımında yapılan işlem yeraltındaki formasyonların Δt (*interval transit time*) değerlerinin ölçülmesidir. Δt , ses dalgasının kaya veya formasyon içinde bir metre veya bir ayak ($foot = ft = 0,30\text{ m}$) ilerlemesi için gereken zamandır, $\mu s/m$ veya $\mu s /foot$ şeklinde ifade edilir. Kayanın ses dalgasını iletme hızı (ses hızı) arttıkça Δt değeri küçülür; hız azaldıkça Δt büyür. Δt değeri kaya türüne ve kayanın gözenekliliğine bağlı olarak değişir.

Sedimanter bir kayanın gözenekliliği yoğunluğu ile bağlantılıdır. Gözeneklilik arttıkça yoğunluk azalır. Yoğunluk azaldıkça buna bağlı olarak ta ses hızı azalır (Δt büyür). Ayrıca kayanın sıkılaşması (kompaksiyon) arttıkça ses hızı artar (Δt küçülür); sıcaklığı arttıkça ses hızı azalır (Δt büyür). Özetle ifade etmek gerekirse, bir kayanın Δt değeri o kayanın gözenekliliği ile doğrudan ilişkilidir.

Sonik log uygulamalarında kullanılan log aletleri çoğunlukla BHC (Borehole Compensated) tipi aletlerdir. Bu tip aletlerde (Şekil 3.12.) biri altta diğeri üstte olmak üzere iki verici (transmitter) ve arada iki çift alıcı (receiver) bulunmaktadır.




Şekil 3.12. Sonik (BHC) log aleti [39].

Vericiden yayılan ses dalgaları kuyu çevresindeki kayalardan geçerek alıcılara gelir. Üst vericiden gönderilen ses dalgaları R_2 ve R_4 alıcıları tarafından, alt vericiden gönderilen ses dalgaları ise R_3 ve R_1 alıcıları tarafından algılanır. Ölçülen iki sürenin (üst verici - R_2 ve R_4 süreleri ile alt verici - R_1 ve R_3 süreleri) ortalaması alınarak Δt hesaplanır. Δt 'den yararlanarak, bir abak yardımıyla kayaların gözeneklilikleri bulunur.

Kömürlere ait Δt değerleri, genellikle kömür seviyelerinin altında ve üstünde yer alan şeyl, çamurtaşı, kumtaşı, kireçtaşı gibi kayaların Δt değerlerinden büyüktür. Örneğin linyitin Δt değeri 140 - 170 $\mu s/ft$, taşkömürününki 110 - 140 $\mu s/ft$ kadardır. Buna karşılık kumtaşında bu değer ortalama 65 $\mu s/ft$, dolomitte ise 43 $\mu s/ft$ 'tir. Bu özelliğinden dolayı sonik log, yeraltında kömür seviyelerinin ayırt edilmesinde önemli katkı sağlayan bir yöntemdir. Burada Δt 'nin kompaksiyona veya bir başka deyişle kömürün gömülmesine bağlı olarak değiştiği dikkate alınmalıdır. Antrasit ve taşkömürü gibi, genel olarak büyük derinliklere gömülmüş kömürler daha fazla katılaşmış olduklarından Δt değerleri küçük, buna karşılık linyit gibi fazla gömülmemiş kömürlerin Δt değerleri daha yüksektir.

Şekil 3.13.'de kömürlü bir sahada açılan sondajda alınmış çeşitli kuyu logları (gamma ray, yoğunluk, sonik, vb.) ve litoloji logu bir arada gösterilmiştir. Sonik logda kömür seviyesi karşısındaki Δt değerleri 150 $\mu\text{s}/\text{ft}$ 'e kadar yükselmektedir. Buna karşılık, gamma-ray logu üzerinde API değerleri, yoğunluk logu üzerinde de yoğunluk değerleri (g/cm^3) ani düşüş göstermektedir.




Şekil 3.13. Kömürlü bir sahaya ait kuyu logu örnekleri [40].

3.3.6. Nötron logu

Bu yöntem ilk kez 1941 yılında ABD'de uygulamaya konulmuştur.

Radyoaktif bir kaynaktan yayılan nötronların kayalar içinden geçişleri sırasında hızlarının yavaşlaması esasına dayalı bir yöntemdir. Log aleti içindeki bir kaynaktan yayılan nötronlar, çevredeki kayalara ve bu kayalar içindeki akışkanlara ait atomların çekirdekleri ile çarpışır; her çarpışmada nötronların enerjisinde, yani hızında bir miktar azalma meydana gelir. Yavaşlamış nötronların hızı, aynı log aleti içine yerleştirilmiş olan bir algılayıcı tarafından saptanır (Şekil 3.14.). Nötronların hızı, algılayıcıda c.p.s. (saniyede darbe sayısı) veya API cinsinden ölçülür.



Şekil 3.14. Nötron logu şeması [35].

Nötronlarda en fazla enerji kaybı hidrojen çekirdeği ile olan çarpışmalarda meydana gelmektedir. Kayaların kapsadığı hidrojen miktarı arttıkça, nötron enerjisindeki kayıp o ölçüde fazla olacak ve alıcıda düşük c.p.s. değerleri ölçülecektir. Formasyonlar içindeki hidrojenin fazla olması, su (H_2O) ve petrol-doğal gaz (C,H) gibi hidrojen bakımından zengin akışkanların varlığına, dolayısıyla formasyonun gözenekli olduğuna işarettir. Bu nedenle nötron logu esas olarak, yeraltında gözenekli seviyelerin ayırt edilmesinde yardımcıdır.

Nötron logu ile belirlenen gözenekliliğe, nötron gözenekliliği denilmektedir. Pratikte log aletinin algılayıcısında kaydedilen c.p.s. (saniyede darbe sayısı) ne kadar küçükse, kayanın gözenekliliği o kadar yüksek demektir.

Tablo 3.3.'de belli başlı mineral ve kaya türlerinin yoğunlukları, ortalama Δt değerleri ve nötron logu ile belirlenmiş olan gözeneklilikleri görülmektedir. Linyit, taşkömürü ve antrasitin görünür (apparent) log yoğunluklarının $0,7 - 1,8 \text{ g/cm}^3$ arasında, Δt değerlerinin ise $110 - 170 \text{ } \mu\text{s/ft}$ arasında değiştiği, gözenekliliklerinin de yüksek olduğu ($> \% 50$) görülmektedir. Şeyller, bazı evaporitler ve kömürlerin nötron gözeneklilikleri yüksektir. Şeyllerde $\% 25 - 60$ dolayındaki nötron gözenekliliği, yalnızca gözenekler içindeki sudan değil, kil minerallerinde bulunan kristal suyundan da kaynaklanabilmektedir. Bu nedenle killi çökellerle arakatlı olan kömür seviyelerinden alınan nötron logları

üzerinde kömür ve kil seviyelerini ayırt etmek genellikle olanaksızdır. Kömür, kil olarak veya kil, kömür olarak algılanabilmektedir.


Tablo 3.3. Bazı mineral ve kayaların ortalama Δt değerleri ve nötron gözeneklilikleri [39].

Mineral/ kayaç	Formül	Yoğunluk (g/cm ³ log)	Ortalama Δt (μ s /ft)	Nötron gözenekliliği (%)
Kalsit	CaCO ₃	2,710	47,5	0
Dolomit (min.)	CaMg(CO ₃) ₂	2,876	43,5	4
Kuvars	SiO ₂	2,648	55,5	-4
Kireçtaşı		2,540	62	10
Dolomit(kaya)		2,683	58	13,5
Kumtaşı		2,485	65,3	3
Şeyl		2,2-2,75	70-150	25-60
Kaya tuzu	NaCl	2,032	67	0
Anhidrit	CaSO ₄	2,977	50	0
Jips	CaSO ₄ .2H ₂ O	2,351	52,5	49
Trona	Na ₂ CO ₃ . NaHCO ₃ .2H ₂ O	2,100	65	40
Silvit	KCl	1,863	74	0
Karnalit	KCl.MgCl ₂ .6H ₂ O	1,570	78	65
Langbeinit	K ₂ SO ₄ .2MgSO ₄	2,820	52	0
Polihalit	K ₂ SO ₄ .MgSO ₄ .2CaSO ₄ .2H ₂ O	2,790	57,5	15
Kainit	MgSO ₄ .KCl.3H ₂ O	2,120	-	45
Sülfür		2,030	122	0
Linyit		0,7-1,5	140-170	> % 50
Taşkömürü		1,3-1,5	110-140	> % 50
Antrasit		1,4-1,8		> % 50

Benzer şekilde jips ve trona gibi bazı evaporitlerdeki yüksek nötron gözenekliliği bu kayalardaki kristal suyundan dolayıdır. Örneğin Tablo 3.3.'de anhidritin bünyesinde su bulunmadığı için nötron gözenekliliği % 0 iken, kristal suyu kapsayan jipsin nötron gözenekliliği % 49 olarak ölçülmektedir.

Kömürlerin (liniyit, taşkömürü, antrasit) nötron gözenekliliklerinin % 50'den büyük olması da kömürü oluşturan elementler arasında hidrojenin, ayrıca her kömürde belli bir miktar suyun ve de metanın CH₄ bulunmasından dolayıdır. Kömürün bu özelliği nötron logunun kömür jeolojisinde uygulanabilirliğini göstermektedir. Şekil 3.15.'de kömürlü bir kuyuya ait nötron ve gamma ray logları kıyaslanmaktadır. Her iki profil arasında

dikkati çeken bir uyum mevcuttur. Nötron logunda, organik madde (kömür) seviyeleri karşısında c.p.s. değerleri ani düşüş göstermektedir. Gamma eğrileri de nötron eğrilerine paralel bir gidiş sergilemektedir.



Şekil 3.15. Kömürlü bir kuyuya ait gamma-ray ve nötron logları [40].

Kömür sondajlarında alınan logların belli başlıları yukarıda özetle anlatılmıştır. Bunlardan başka sıcaklık ve kaliper gibi diğer loglar da bulunmaktadır.

Sıcaklık logu yeraltı işletmeciliğinin söz konusu olduğu sahalarda alınır ve yerin herhangi bir derinliğindeki yer sıcaklığını verir.

Kaliper logu, yüzeyden derine doğru inildikçe kuyu çapındaki değişiklikleri gösterir. Örneğin kuyuda yıkıntı olan seviyeler (kuyu çapında ani genişleme) kaliper logu ile saptanabilmektedir.

BÖLÜM 4. UYGULAMA

Günümüzde hızla artan insan nüfusu ve sanayileşme ile birlikte, kişi ve fabrika başına düşen enerji tüketimi de hızla artmaktadır. Böylece yeni enerji kaynaklarının araştırılması, bulunması ve en iyi verimle kullanıma açılması büyük önem taşımaktadır. Eğer bu aşamaların tümü gerektiği gibi yapılırsa, hem ülke ekonomisine hem de doğal kaynakların korunmasına büyük katkı sağlanmış olur.

Çalışmada, Soma Havzasında kömür varlığı tahminine yönelik YSA ve ANFIS modeli ile oluşturulmuş ve bu tekniklerin tahmin gücünün analizi uygulanmıştır.

Yeraltı litolojisinin fiziksel, elektriksel ve akustik özellikleri çoğu kömür araştırmalarında karar verici olarak kullanılmaktadır. Bu özellikler kömür yataklarının kalınlık ve derinliğinin, tanımlanması ve tam olarak belirlenmesi amacıyla çok kullanılmaktadır. Fakat karmaşık yeraltı jeolojisinde tabaka türünün tanımlanması oldukça zordur. Son zamanlarda YSA ve ANFIS çeşitli mühendislik branşlarında karmaşık problemlerin çözümünde yaygın olarak kullanılmaktadır. Bu çalışma bilinen klasik yöntemlerin aksine, YSA ve ANFIS yardımıyla kömür tabakalarının varlığının tahminine yöneliktir. Yeni açılacak sondajların iş hacimleri ve maliyetleri göz önüne alındığında YSA ve ANFIS ile yapılacak bu tür çalışmalar işgücü ve maliyet açısından bir çok avantajı beraberinde getirecektir.

Çalışmada giriş parametresi olarak nötron, gamma ray ve yoğunluk kullanılmıştır. Bu datalar Soma Kömür Havzası olarak adlandırılan kömür araştırma sahasına aittir. Bu havza yaklaşık KD-GB doğrultusunda 40km boyunca uzanan bir alanı


kapsamaktadır. Bu çalışmada Soma Kömür Havzasında mekanik olarak açılan 10 adet sondaj kuyusunun jeofizik kuyu logu parametreleri kullanılmıştır. Bu kuyulara ait yüksek orandaki veri hacmi ve sayısı çalışmanın sıhhati açısından son derece önemli ve avantajlıdır. Bu kapsamda kuyu logu datalarından kömür tabakalarının varlığının tahmin edilmesi sinirsel ağlarla tam tamına uymaktadır. Bu çalışma, yapay sinir ağı (YSA) ve ANFIS yaklaşımı kullanılarak dijital kuyu logu verilerinden kömür damarlarının varlığını tahmin etmeyi amaçlamaktadır. Temel verilerin yüksek isabet oranı ve tahmin değerleri tekniğin hassasiyetini yansıtır. YSA ve ANFIS rezervlerin modellenmesi ve karakterlerinin tahmin edilebilmesi için hızlı ve yüksek doğrulukta sonuç veren bir metottur.

Kuyu logları neredeyse bir yüzyıldır olası kömür ve hidrokarbon rezerv varlığının belirlenmesi için kullanılmaktadır. Log analistleri, kuyunun petrofizik özelliklerini belirlemek için log datalarını yorumlamaktadır [41]. Modern log tekniği, kuyuda akla gelebilecek her türlü fiziksel ve kimyasal özelliğin ölçülmesini sağlamaktadır. Kuyu logu datalarının nitel ve nicel yorumlarının etkin bir biçimde yapılması öncelikle kuyu datalarının sağlıklı biçimde toplanmasına bağlıdır. Bir log aletinin verimli biçimde çalışması için ortamın log alımına uygun olması gerekir. Log alımından önce derinlik, basınç, sıcaklık, kuyu çapı, sondaj çamuru ve yönlü kuyuların uygunluğu önceden araştırılmalıdır.

Kömür arama aşamasında genellikle gamma-ray, yoğunluk, nötron, SP, rezistivite, kaliper ve akustik ölçüler yaygın biçimde kullanılmaktadır [37]. Bu log parametrelerinin derinlikle değişkenliği ve gösterecekleri genlikler yeraltı stratigrafik değişkenliklere bağlıdır. Yeraltı heterojen yapısının değişmesi ve göreceli tabakaların kalınlıkları, log datalarının tepkisinin ayırt edilmesinde yardımcı olmaktadır. Geçiş zonları ve ince tabakalar, komşu tabakalardan çok etkilenir ve farklı-karmaşık tepkiler verebilirler. Uygun metodoloji eksikliği nedeniyle kişisel önyargı ve deneyimi, günlük verilerin etkin yorumlanmasında önemli bir rol oynamaktadır.

Bu çalışmada kullanılan kuyular Türkiye'nin Batı Anadolu Bölgesinde yer alan Manisa ili, Soma kömür havzası Yaylaköy civarındadır (Şekil 4.1.). Amaca yönelik

olarak bu bölgede açılan kuyuların jeolojik sondaj kesitleri ve jeofizik kuyu logları kullanılmıştır. Bu kuyular, TKİ(Türkiye Kömür İşletmesi) tarafından kömür arama amaçlı olarak açılmıştır. Çalışmanın amacı olan YSA ve ANFIS ile kömür tahmini yapılmasında, bu kuyulara ait stratigrafisi bilinen jeofizik kuyu logları kullanılmıştır. Çalışmada 10 adet gibi yüksek oranda sondaj kuyusunun jeofizik kuyu logu parametreleri kullanılarak, veri hacmi yüksek oranda seçilmiş olup YSA ve ANFIS ile sahada sorunun çözümüne büyük oranda yaklaşılmaya çalışılmıştır.



Şekil 4.1. Çalışma alanı lokasyon haritası

4.1. Çalışma Alanı Jeolojisi

Çalışma alanının jeoloji haritası Şekil 4.2.'de sunulmuştur. Çalışma sahasında Neojen öncesi temel kayalar Paleozoyik yaşlı şist-grovak ve Mesozoyik yaşlı kristalize kireçtaşları oluşturmaktadır. Şist ve grovak grimsi mavi ve kahverengimsi renklidirler. İnce taneli olup tabakalanma göstermezler. Kısmen metamorfize olmuşlardır. Yer yer üst seviyelerinde killi şistler gözlenmektedir. Kristalize kireçtaşları bazen orta-kalın tabakalanmalı olup, genelde masiftirler. Gri, açık gri-beyaz renklidirler. Çatlaklı ve kalsit dolguludur. Grovaklar üzerine uyumsuz gelirler. Şekil 4.3.'te görüldüğü gibi, Neojen Miyosen yaşlı çakıltı-kumtaşı-silttaşı-kıltaşı

(M1), marn (M2), kireçtaşı (M3), kumtaşı-silttaşı-alacalı kil (P₁), marn-kiltaşı-tüf (P2ab), konglomera-kumtaşı-kiltaşı (P_{2c}) ve silisifiye kireçtaşı (P3) birimlerinden meydana gelmiştir. Orta-Üst Miyosen yaşlı örtü volkanitleri (Pltv) en üst birimleri oluşturur [42].


Miyosen yaşlı çökeller içerisinde M1 – M2 geçişinde (KM2), M3'ün üst seviyelerinde (KM3) ve P1'in üst seviyelerinde (KP1) olmak üzere 3 kömür horizonu bulunmaktadır. Çalışma alanında her üç kömür mostrası da gözlenmemektedir. Bu kömür oluşumlarından, KM2 horizonu düşey-yanal devamlılığı olan ve yüksek kalori değerine sahip kömürdür.

Batı Anadolu'da Tersiyer volkanizması üzerinde çalışan araştırmacılar Ercan ve diğerleri [43], volkanizmanın Oligosen'den başlayıp birkaç aktif, birkaç sakin devre geçirerek çeşitli karakterlerde Geç Miyosen'e kadar devam ettiği görüşündedirler. Çalışma alanında çok geniş alanlar kaplayan andezit, tüf, silisleşmiş tüf, lahar ve aglomeralardan oluşan birime Ercan v.d. Yunt'dağı volkanitleri adını vermişlerdir. Yunt'dağı volkanitleri örtü volkanitleri şeklinde gözlenmektedir.


Miyosen öncesi büyüme fayları temel kayaçların KD-GB yönlü grabenler şeklinde çökmesine neden olmuştur. Bu graben havzaları linyit oluşumlarını da içeren Neojen çökelleri için gerekli çanakları oluşturmuştur. Geç Miyosen döneminde genişleme kırıkları şekline dönüşen bu ana hatlar boyunca volkanik faaliyet gözlenmektedir. Bu hatlar üzerinde volkanik merkezlerde bulunmaktadır. Tektonizmanın yoğun olduğu bölgeler aynı zamanda volkanizmanın da çeşitlendiği yerlerdir. Ara tektonik hatları KD-GB yönlü, batıya doğru düşen basamak faylar oluşturur.

Batı Anadolu'da Geç Oligosen'de gelişmiş KD-GB gidişli doğrultu atımlı fayların En Geç Oligosen-Erken Miyosen'de batıdan doğuya doğru sıra içerisinde eğim atımlı faylar şeklinde işlemesiyle KD-GB gidişli grabenler açılmıştır [44]. KD-GB uzanımlı Soma kömür havzası bu grabenlerden birinde gelişmiştir. Geç Miyosen-Erken Pliyosen'de tüm Batı Anadolu'da hakim olan etkin K-G yönlü gerilme kuvvetleri, D-B yönlü grabenlerin oluşmasına neden olmuştur. Bu graben havzaları akarsu ve göl

fasiyesinde oluşan kil, kum, çakıl ve kireçtaşlarından oluşan genç çökellerle kaplanmıştır.



Şekil 4.2. Çalışma alanı jeoloji haritası [42].



Şekil 4.3. Soma bölgesinin genelleştirilmiş stratigrafik kesiti [42].

4.2. Sondaj Litolojisi (Stratigrafisi) ve Jeofizik Kuyu Logları

Manisa-Soma kömür havzası KD-GB doğrultusunda 40 km boyunca uzanan 7 sektörden oluşmaktadır. Çalışmada sunulan sondajlar, bu havzanın güneyinde bulunan Eynez sektöründe Yaylaköy civarında bulunmaktadır. Kömür içeren formasyon Miyosen yaşlı Soma formasyonudur. Bu formasyon güneyde volkanitlerin altına dalmaktadır. Soma Havzası kömür sondajlarına ait kömür laboratuvar sonuçları Tablo 4.1.'de verilmiştir. Kömürlerin kalitesi ve özelliklerini ortaya koyan analiz türleri kalori (ısısal), kısa ve elementel analizleridir. Çalışma kapsamında nem, kül, uçucu madde, sabit karbon, kükürt ve kalori analizleri yapılmıştır. Bu analizler bir kömürün petrografik analizler ile birlikte niteliklerini ortaya koyabilmektedir. Kül yüzdesi kömürün kalitesini belirleyen önemli bir parametredir. Tablo 4.1.'de görüldüğü gibi nem, özellikle kül oranı arttıkça kömür kalori değerinin azaldığı gözlemlenmektedir. Kömür kalori değerleri 3000 - 5700 kkal/kg arasındadır. Kömür yatak kalınlığı ise 4,83 – 23,88 m arasında değişmektedir.

Tablo 4.1. Kömür kuyularının fiziksel özellikleri

Kuyu adı	%					Kömür Yatak Kalınlığı (m)
	Su	Kül	Uçucu Madde	Sabit C(carbon)	+S(Kükürt)	
EY-321	12,11	23,3	32,7	31,89	1,19	4138-4396
EY-330	8,66	35,94	28,06	27,34	1,00	3451-3662
EY-333	12,57	22,71	34,25	30,47	1,00	4001-4260
EY-339	11,49	25,07	39,81	23,63	0,81	3421-3671
EY-340	15,41	13,99	35,42	35,18	2,19	4753-5049
EY-341	17,95	14,02	33,86	34,18	1,77	4398-4694
EY-342	13,88	17,54	35,14	33,43	0,82	4422-4698
EY-347	12,51	10,73	33,86	42,90	1,80	5393-5680
EY-348	13,45	27,98	37,73	20,85	0,96	3011-3258
EY-351	13,67	32,65	28,31	25,37	3,43	3281-3509

Şekil 4.4. - 4.13.'de bu sondaj kuyularına ait litolojik düşey kesit ve jeofizik kuyu logları görülmektedir. Bu kuyu litolojilerinde jeolojik birimler derinlik sırasına göre marn, kömür, kıltaşı, kumtaşı, çakıltaşı, konglomera, kireçtaşı ve şist-grovaktır.

Kuyu log ölçümleri kömür arama aşamasında yapılmış olup; gamma-ray, nötron ve yoğunluk ölçü yöntemleri kullanılmıştır. YSA ve ANFIS’de giriş verilerini tanımlayabilmek amacıyla jeolojik birimlere karşılık gelen jeofizik kuyu logları sayısallaştırılmış olup, sayısal aralıkları Tablo 4.2.’de verilmiştir.


Hidrojen, nötronları çok iyi yavaşlattığından, aynı zamanda nötron logu kömür tabakalarında yüksek bir zahiri gözeneklilik gösterir. Herhangi bir mineralin hidrokarbon kömürden daha yüksek yoğunluğu olduğu için, yoğunluk logu bir kömür bantları diziminin üzerindeki kül miktarı değişimlerini de değerlendirmede kullanılabilir. Kömür tabakaları yoğunluk ve nötrondan okunan yüksek zahiri gözenekliliği karşılaştırarak jeofizik kuyu loglarından tanınabilirler. Aşağıda Tablo 4.2.’de görüleceği gibi nötron logunda hidrojenin nötron parçalarını çok iyi tuttuğundan dolayı kömür seviyesinde proba gelen partiküller diğer birimlere göre azdır. Yoğunluk(Density) logunda kömür seviyesinde okunan değerler zahiri gözenekliliği karşılaştırmada kullanılabilir. Tablo 4.2.’de görüleceği gibi kömür seviyesinde ölçülen yoğunluk log değerleri diğer birimlere göre yüksek cps değerleri vermektedir. Kömür tabakaları genelde kumtaşlarından bile daha az gamma-ray değerleriyle jeofizik kuyu loglarından tanınabilirler ancak çalışma sahasındaki kömürlerde yüksek radyoaktiviteye neden olan gaz girişleri olması nedeniyle, kömür seviyelerinde yüksek gamma-ray değerleri ölçülmüştür.

Tablo 4.2. Farklı jeolojik tabakalar ve karşılık gelen kuyu logu parametreleri


Kuyu Adı	Tabaka/Log	Gamma-Ray(API)	Nötron(cps)	Density(cps)
EY-321	Marn	22-90	350-750	15-72
	Kömür	20-600	90-450	90-180
	Kiltaşı	105-160	250-365	60-110
	Kumtaşı	115-155	365-505	50-85
	Şist-grovak	90-150	260-375	45-90
EY-330	Marn	10-100	55-360	5-16
	Kömür	62-509	20-80	23-85
	Kiltaşı	45-200	48-84	8-20

Tablo 4.2. (Devamı)


EY-333	Marn	7-53	900-1600	9-67
	Kömür	25-150	300-660	22-104
	Konglomera	44-56	800-1200	7-17
	Şist-grovak	26-40	1200-1270	9-11
EY-339	Marn	12-173	70-277	18-34
	Kömür	12-90	24-122	27-78
	Konglomera	67-81	103-160	18-41
	Şist-grovak	65-85	180-250	6-20
EY-340	Marn	6-72	157-460	6-11
	Kömür	145-540	17-80	27-84
	Kiltaşı	36-220	43-180	5-51
EY-341	Marn	13-75	110-250	200-280
	Kömür	9-290	20-165	265-325
	Kireçtaşı	9-270	135-235	205-300
	Kiltaşı	20-90	40-175	230-320
	Şist-grovak	40-75	80-210	190-320
EY-342	Marn	4-60	170-400	10-60
	Kömür	35-280	45-240	60-110
	Kiltaşı-Kumtaşı	55-110	170-430	28-55
	Şist-grovak	60-120	155-300	40-65
EY-347	Marn	2-20	140-660	13-90
	Kömür	18-55	37-280	70-265
	Kiltaşı	2-17	220-320	9-55
EY-348	Marn	180-313	127-371	29-68
	Kömür	90-330	48-320	50-100
	Kiltaşı	123-220	70-152	56-82
	Kireçtaşı	205-305	201-338	37-56
	Konglomera	184-246	200-290	13-49
	Şist-grovak	190-215	235-275	7-19
EY-351	Marn	10-60	50-175	11-25
	Kömür	30-570	10-80	50-130
	Kiltaşı	50-330	10-40	25-110
	Kireçtaşı	10-170	60-300	8-25




Şekil 4.4. EY-321 kuyusuna ait kuyu logu ve litolojisi




Şekil 4.5. EY-330 kuyusuna ait kuyu logu ve litolojisi




Şekil 4.6. EY-333 kuyusuna ait kuyu logu ve litolojisi




Şekil 4.7. EY-339 kuyusuna ait kuyu logu ve litolojisi




Şekil 4.8. EY-340 kuyusuna ait kuyu logu ve litolojisi




Şekil 4.9. EY-341 kuyusuna ait kuyu logu ve litolojisi




Şekil 4.10. EY-342 kuyusuna ait kuyu logu ve litolojisi



Şekil 4.11. EY-347 kuyusuna ait kuyu logu ve litolojisi




Şekil 4.12. EY-348 kuyusuna ait kuyu logu ve litolojisi



Şekil 4.13. EY-351 kuyusuna ait kuyu logu ve litolojisi

4.3. Çalışmada Kullanılan Modeller

Uygulama Manisa İli, Soma Havzası bölgesindeki kömür araştırma kuyularından elde edilen Neutron(cps), Gamma(Apı) , Density(cps) ve kömür çıkma durumuna ait veriler kullanılarak gerçekleştirilmiştir. Bu değişkenlerden neutron, gamma, density değişkenleri girdi, bu değişkenlere ait derinlikte kömür bulunma durumu çıktı olarak ele alınmıştır. Kömür havzasındaki 10 adet kuyudan 6'sı (EY321, EY330, EY333, EY340, EY341, EY348) eğitim seti, 4 tanesi (EY339, EY342, EY347, EY351) ise test seti olarak kullanılmıştır (Şekil 4.14.).



Şekil 4.14. Soma havzasına ait YSA ve ANFIS uygulamasında eğitim ve test seti olarak kullanılan kuyular

6 adet kuyuda eğitim setinde 36009 adet veri eğitilmiştir. Test setinde ise 4 kuyudan toplam 23008 veri kullanılmıştır. Değişkenlere ait 59017 adetlik veri setinin %61 i (36009 adet) eğitim seti, %39 si (23008) ise test seti olarak ayrılmıştır. Uygulamasına başlamadan önce tüm veriler, sağlıklı sonuçların elde edilmesi için aşağıdaki formüller kullanılarak -1 ile +1 arasında normalize edilmiştir;

$$X_i = 2 \cdot \frac{X_i - X_{min}}{X_{max} - X_{min}} - 1 \quad (4.1)$$

X_i = normalize edilmiş değerler

X_{min} = i girdisine ait ölçümlerin minimum değeri

X_{max} = i girdisine ait ölçümlerin maksimum değeri


Normalize edilmiş değerler MATLAB paket programının Neural Network toolbox ve ANFIS editörüne aktarılarak değerlendirilmiştir.

Eğitilip tamamlanan ağlara test verileri verilerek kömür tahmin çıktıları elde edilmiştir. Elde edilen ve -1 (kömür yok) ile 1 (kömür var) arasında ondalıklı olarak değişen kömür tahmin çıktıları değerleri ağ modellerin sonuçlarının kalitesini görmek için değerlendirilmiştir. Değerlendirmede öncelikle 0'ın üstündeki değerler +1'e, 0'ın altındaki değerler ise -1'e yuvarlanmıştır.

4.3.1. Yapay sinir ağları modeli

Oluşturulan yapay sinir ağı modelinde 3 katmanlı bir ağ yapısı kullanılmıştır.

Oluşturulan yapay sinir ağı modelinde biri gizli katman olmak üzere 3 katmanlı bir ağ yapısı kullanılmıştır (Şekil 4.15.).



Şekil 4.15. Uygulamada kullanılan yapay sinir ağının yapısı

Girdi katmanında üç, çıktı katmanında bir çıktı olmak üzere, ara katmanda da sırasıyla 3, 5, 10, 20 ve 50 düğümün(N) performansları hesaplanmıştır. Karşılaştırılan farklı düğüm sayılarına ağ modellerinin hepsinde ileri beslemeli geriye yayımlı ağ modeli kullanılmıştır. Kurulan modellerde eğitim ve öğrenme fonksiyonu olarak gradient descent with momentum metot, performans fonksiyonu olarak da ortalama karesel hata (MSE) seçilmiştir;


$$MSE(Hataların Kareleri Ortalaması) = \frac{\sum_{i=1}^n (y' - y)^2}{n} \quad (4.2)$$

y' = tahmini değer

y = gerçek değer

n = veri adedi

Farklı düğüm sayılarından oluşan ağ modellerine hazırlanılan eğitim seti verilerek 10000 iterasyonluk bir eğitim sürecinden geçirilmişlerdir. Uygulamada kullanılan ağlara ait eğitim seti sonuçları Şekil 4.16.'da verilmiştir.




Şekil 4.16. Farklı düğüm sayılarına sahip YSA modellerin eğitim sonuçları

Şekil 4.16.'da yer alan farklı düğüm sayılarına ait eğitim sonuçları incelendiğinde eğitim sürecinin sonlarına doğru hata oranlarında sabitlik söz konusu olduğundan deneme yanılma ile belirlenen 10000 iterasyonluk eğitim süreci yeterli görülerek durdurulmuştur.

Test setlerinin gerçek çıktı değerleri ile yapay sinir ağı modellerine ait tahmin değerleri arasındaki korelasyon katsayıları hesaplanarak karşılaştırılmış ve aşağıdaki sonuçlar elde edilmiştir (Şekil 4.17. - 4.21.).

YSA Uygulamaları	Düğüm Sayısı	Tahmin Sonuçlarının Korelasyon Katsayısı	Hatalı Tahmin Yüzdesi(%)
Uygulama 1	N=3	0,74	8,4
Uygulama 2	N=5	0,68	10,2
Uygulama 3	N=10	0,74	8,7
Uygulama 4	N=20	0,72	9,0
Uygulama 5	N=50	0,71	9,1




Şekil 4.17. 4 Kuyuya ait 23008 adet test verisi üzerinden YSA sonuçları

Oluşturulan ağ modelleri ilk etapta test setinde yer alan 4 kuyuya ait 23008 adet test verisi bir araya getirilerek değerlendirilmiştir. Şekil 4.17.'de yer alan sonuçlar incelendiğinde 3 düğüm sayılı ağ modelinin 0,74 korelasyon katsayısı ve % 8,4 hatalı tahmin yüzdesi ile diğer düğüm sayılarına ait YSA modellerinden daha iyi sonuç verdiği görülmektedir.


Oluşturulan YSA modellerinin test setinde yer alan kuyuların her birindeki performansının değerlendirilebilmesi için birbirinden bağımsız olarakda analiz edilmiştir (Şekil 4.18. - 4.21.).

YSA Uygulamaları	Düğüm Sayısı	Tahmin Sonuçlarının Korelasyon Katsayısı	Hatalı Tahmin Yüzdesi(%)
Uygulama 1	N=3	0,69	13,3
Uygulama 2	N=5	0,68	13,8
Uygulama 3	N=10	0,68	14,1
Uygulama 4	N=20	0,62	16,4
Uygulama 5	N=50	0,61	16,6




Şekil 4.18. EY-339 kuyusuna ait 4132 adet test verisi üzerinden YSA sonuçları


YSA Uygulamaları	Düğüm Sayısı	Tahmin Sonuçlarının Korelasyon Katsayısı	Hatalı Tahmin Yüzdesi(%)
Uygulama 1	N=3	0,81	5,1
Uygulama 2	N=5	0,80	5,1
Uygulama 3	N=10	0,79	5,6
Uygulama 4	N=20	0,80	5,4
Uygulama 5	N=50	0,78	5,9



Şekil 4.19. EY-342 kuyusuna ait 8301 adet test verisi üzerinden YSA sonuçları



Şekil 4.20. EY-347 kuyusuna ait 3674 adet test verisi üzerinden YSA sonuçları




Şekil 4.21. EY-351 kuyusuna ait 6901 adet test verisi üzerinden YSA sonuçları

EY-339, EY-342, EY-347 ve EY-351 numaralı kuyulara ait sonuçlar değerlendirildiğinde tüm test kuyularında N=3 düğüm sayısına ait modellerin test kuyularının genelinde 0,69 – 0,81 arasında değişen yüksek korelasyon katsayısı ve % 6,8 - %13,6 arasında değişen düşük hatalı tahmin yüzdesi ile nispeten daha iyi sonuçlar verdiği görülmektedir. Kuyu bazlı değerlendirme yapıldığında en iyi sonucun 0,81 korelasyon katsayısı ve % 94,9 doğru tahmin etme oranı ile N=3 düğümünde EY-342 numaralı kuyudan elde edildiği görülmektedir.

4.3.2. ANFIS modeli

Çalışmada kullanılan ANFIS yapısı Şekil 4.22.'de gösterilmektedir. Giriş parametresi olarak nötron, gamma ray ve yoğunluk, çıkış parametresi olarak da kömür varlığını içermektedir.



Şekil 4.22. Uygulamada kullanılan ANFIS yapısı

Performans kriteri olarak ortalama mutlak hata (MAE) seçilmiştir. Ortalama mutlak hata şu formülle bulunur;

$$MAE = \frac{1}{n} \sum_{i=0}^n |f_i - y_i| = \frac{1}{n} \sum_{i=0}^n |e_i| \quad (4.3)$$

Adından da anlaşılacağı gibi, ortalama mutlak hata, hataların mutlak ortalamasıdır.

$e_i = |f_i - y_i|$, burada f_i tahmindir ve y_i gerçek değerdir.

ANFIS ile kurulabilecek en iyi modeli belirleyebilmek için farklı giriş üyelik fonksiyonları ve çıkış üyelik fonksiyonları denenmiş ve uygulanan bazı modellere ait R (Korelasyon Katsayısı), MAE değerleri hesaplanmıştır. Hesaplanan değerler Tablo 4.3.'te verilmiştir. Tablo 4.3.'te ANFIS modellerinde giriş üyelik fonksiyonu (Mf) olarak trap (yamuk), pi (π), tri (üçgen), gauss2, dsig (sigmodial – tam simetrik) ve psig (sigmodial) olarak seçilmiştir.

Tablo 4.3.'te en iyi modelin her bir giriş için 3'er adet Pi(π) tipi üyelik fonksiyonu, 250 epoch sayısı ve çıkış için de constant(sabit) tipi üyelik fonksiyonunun seçilmesiyle oluşturulduğu bulunmuştur.

Tablo 4.3. 4 Kuyuya ait 23008 adet test verisi üzerinden ANFIS sonuçları

Giriş Mf Türü-Mf Sayısı- Epoch-Çıkış Mf Türü	R	MAE (%)
Trapmf-3 3 3 -250-constant	0,73	0,34
Pimf-3 3 3 -250-constant	0,71	0,33
Trimf-3 3 3 -200-constant	0,72	0,38
Gauss2mf-333-250constant	0,69	0,35
Dsigmf-3 3 3 -250-constant	0,71	0,36
Psigmf-3 3 3 -250-constant	0,71	0,36
Trapmf-6 6 6 -200-constant	0,69	0,35
Pimf-6 6 6 -200-constant	0,70	0,35
Trapmf-8 8 8 -150-constant	0,69	0,37

Tablo 4.4. Test kuyularına karşılık gelen ANFIS sonuçları (Pimf)

Kuyu Adı	R	MAE (%)
EY-339	0,64	0,59
EY-342	0,78	0,20
EY-347	0,72	0,35
EY-351	0,75	0,32

EY-339, EY-342, EY-347 ve EY-351 numaralı kuyulara ait sonuçlar değerlendirildiğinde; Test kuyularında 0,64 – 0,78 arasında değişen korelasyon katsayısı ile iyi sonuçlar verdiği görülmektedir. ANFIS modellerinde hatalı tahmin yüzde aralığı ise 0,20 - 0,59 aralığında elde edilmiştir (Tablo 4.4.).

BÖLÜM 5. SONUÇ VE ÖNERİLER

Doğal olayları klasik metotlarla modellemek her zaman kolay değildir. Soma Havzasında yapılan kömür arama sondajlarından ölçülen kuyu log veri kalitesi yüksektir. Çalışmada mekanik olarak açılan 10 adet sondaj kuyusunun jeofizik kuyu logu parametreleri kullanılmıştır. Bu kuyulara ait yüksek oranda veri hacmi ve sayısının olması çalışmanın sıhhati açısından son derece önemli ve avantajlıdır. YSA ve ANFIS yaklaşımıyla yüksek orandaki bu veri hacminin değerlendirilmesi kolay olabilmektedir. Mekanik olarak açılan bir kömür arama sondajının maliyetini ve iş hacmini düşündüğümüzde, YSA ve ANFIS tabanlı yapılacak çalışmalar çok ucuz maliyet ve iş hacmi meydana getirecektir.

Bu çalışmada yapay zeka tekniklerinden olan ve karmaşık sistemleri modellemede sıkça kullanılan YSA ve ANFIS metotları kullanılarak 10 adet kömür araştırma kuyusundan elde edilen 59017 adet veriden kömür varlığı tahmin edilmeye çalışılmıştır.

YSA'da en iyi modelin belirlenmesi için farklı düğüm sayılarında uygulama tekrarlanmış ve doğal olaylar için yüksek sayılabilecek bir doğrulukta kömür varlığının tahmin edildiği görülmüştür. Sonuçlar kuyu bazında değerlendirildiğinde bölgedeki farklı kuyulardan elde edilen jeofizik kuyu logu verileriyle YSA'da N=3 düğüm sayılı model için % 94,9 ile % 86,4 arasında değişen doğruluk oranlarında kömür varlığının tahmin edilebildiği görülmektedir. Test edilen kuyular birlikte değerlendirildiğinde de doğruluk oranı % 91,6 olarak hesaplanmıştır. YSA'da oluşturulan ileri beslemeli geri yayımlı modelde düğüm sayısı arttıkça tahmin hatalarının çok az miktarda arttığı gözlemlenmiştir. YSA sonuçlarının hata oranındaki düşüklük, kömürün çıkarılması sürecinde büyük sahalardan alınacak daha az veri ile zaman ve para tasarrufu sağlanarak kaynakların daha etkin kullanılabileceği noktasında umut vericidir. YSA'da oluşturulan ağ modeli, çok

sensörlü jeofizik logu datalarının kullanılmasıyla, tabakanın tanımlanmasında kullanılabilir.

ANFIS modelinde ise toplam 4 kuyu için %71 civarında korelasyon katsayısının hesaplandığı görülmektedir. Test edilen kuyular ayrı ayrı değerlendirildiğinde de en iyi sonucun %78 korelasyon katsayısı ve 0,20 mutlak hata ile EY-342 nolu kuyudan elde edildiği görülmektedir. ANFIS gibi farklı yapay zeka teknikleriyle de bu ve benzer alanlarda kullanılarak başarılı sonuçlar elde edilebilir.

YSA ve ANFIS gibi yapay zeka modellemelerinde veri seti için uygun modelin ortaya çıkarılması esnasında birçok deneme yapılmalıdır. Veriler için örneklerin seçimi, hangi öğrenme metodunun kullanılacağı, veri kümesinin büyüklüğü ve çeşitliliği, kullanılacak eğitim, öğrenme ve üyelik fonksiyonunun tipi çıktı değerlerinin kalitesini belirleyen unsurlar olduğundan, en iyi sonucu elde edene kadar denemelerin tekrarlanmasında fayda olacaktır.

KAYNAKLAR

- [1] Öztemel, E., Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 2003.
- [2] Kalogirou, S. A., Artificial neural networks in renewable energy systems applications: a review, Renewable and Sustainable Energy Reviews. (5), 373–401, 2001.
- [3] Baş, N., Yapay Sinir Ağları ve Bir Uygulama, Yüksek Lisans Tezi, Mimarşinan Güzel Sanatlar Üniversitesi, İstatistik Ana Bilim Dalı, İstanbul, 2006.
- [4] Saraç, T., Yapay Sinir Ağları, Basılmamış Seminer Projesi, Gazi Üniversitesi Endüstri Mühendisliği Bölümü Anabilim Dalı, Ankara, 2004.
- [5] Gurney, K., Computers and Symbols versus Nets and Neurons, UCL Draft Papers, No:1, U.K, 1996.
- [6] Patro, S., Neural Networks and Evolutionary Computation for Real-time Quality Control, A Dissertation in Industrial Engineering, Texas Tech University, 1997.
- [7] Kaya, İ., Oktay, S., Engin, O., Kalite kontrol problemlerinin çözümünde yapay sinir ağlarının kullanımı, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü Dergisi, 21 (1-2), 92-107, 2005.
- [8] Gülseçen, S., Yapay Sinir Ağları, İşletme Alanında Uygulanması ve Bir Örnek Çalışma, Basılmamış Doktora Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü İşletme Fakültesi Sayısal Yöntemler Anabilim Dalı, İstanbul, 1993.
- [9] Rojas, R., Neural Networks-A Systematic Introduction. Berlin: Springer-Verlag, 1996.
- [10] D.E. Rumelhart and J.L. McClelland., Parallel Distributed Processing, Vol. 1, MIT Press, Cambridge, 1986.
- [11] Anderson, D.and McNeill, G., Artificial Neural Networks Technology, Kaman Sciences Corporation, New York, 1992.

- [12] Jain.,A.K. and Mao J., Artificial Neural Networks: A Tutorial, IEEE Computer Special Issue on Neural Computing, 1996.
- [13] Doğan, G., Yapay Sinir Ağları Kullanılarak Türkiye'deki Özel Bir Sigorta şirketinde Portföy Değerlendirmesi, Yüksek lisans tezi, Hacettepe Üniversitesi, Ankara, 2010.
- [14] White, H., Connectionist Non-parametric Regression : Multilayer Feedforward Networks Can Learn Arbitrary Mappings, Neural Networks, p. 535-550, 1990.
- [15] Chowdary, B.V., Back-Propagation Artificial Neural Network Approach for Machining Centre Selection, Journal of Manufacturing Technology Management, 18 (3), p. 315-332, 2007.
- [16] Çelebi, D., Bayraktar, D., An Integrated Neural Network and Data Envelopment Analysis for Supplier Evaluation Under Incomplete Information, Expert Systems with Applications, 35, p. 1698–1710, 2008.
- [17] Günay, S., Eğrioğlu, E., Aladağ, Ç.H., Tek Değişkenli Zaman Serileri Analizine Giriş, Hacettepe Üniversitesi Yayınları, Ankara, 2007.
- [18] Mandic, D.P., Chambers, J. A., Recurrent Neural Networks for Prediction - Learning Algorithms Architectures and Stability, John Wiley & Sons Ltd, 2001.
- [19] Aladağ, Ç.H., Eğrioğlu, E., Günay, S., Yapay Sinir Ağları ile Türkiye Elektrik Tüketiminin Tahmini, TUIK 16. İstatistik Araştırma Sempozyumu Bildiriler Kitabı, s. 181-191, 2007.
- [20] Tebelkis, J., Speech Recognition Using Neural Networks, Ph.D. Thesis, Carnegie Mellon University, Pennsylvania, 1995.
- [21] Saritas, İ., The Design of Magnetic Filter for Cleaning Industrial Liquids and Adaptive Control of Filter by Artificial Intelligence Methods, Phd Thesis, Selcuk University Institute of the Natural and Applied Sciences, 2008.
- [22] Alkan, A., Predictive Data Mining with Neural Networks and Genetic Algorithms, Ph.D. Thesis, İTÜ, İstanbul, 51, 2001.
- [23] Sarıkoç, M., Dinamik Sistemlerin ANFIS ile Modellenmesinde Yayılimcı Rekabetçi Optimizasyon (Ica) Algoritmasının Kullanılması, Yüksek Lisans Tezi, BİLECİK, Ref. No: 10043137, 2014.

- [24] Türkbey, O., Makina sıralama problemlerinde çok amaçlı bulanık küme yaklaşımı, Gazi Üniversitesi Müh. Mim. Fakülte Dergisi, 18: 63-77, 2003.
- [25] Şentürk, S., Faktöriyel tasarıma adaptif ağ tabanlı bulanık mantık çıkarım sistemi ile farklı bir yaklaşım, Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 22: 57-74, 2010.
- [26] Elmas, Ç., Bulanık mantık denetleyiciler, Seçkin Yayıncılık, Ankara, 2003.
- [27] Şenol, C., Yildirim, T., Bulanık-Sinir Ağı Yapısı için Yeni Bir Karma Yaklaşım, Elektrik-Elektronik ve Bilgisayar Mühendisliği Sempozyumu, Bursa, 2008.
- [28] Çakıroğlu, M.A., Erenoğlu, E., Kasap, S., Ekiz, Y., Çelik lif katkılı betonların tahribatsız deney yöntemleriyle elde edilen basınç dayanımının ANFIS metoduyla tahmini, SDU International Technological Science, 3(3): 14-22, 2011.
- [29] Tsoukalas, L.H., Uhrig, R.E., Neuro fuzzy approach for anticipatory control of complex systems, IEEE International Conference in Fuzzy Systems, (1):587- 593, 1996.
- [30] Özçalık, H.R., Uygur, A.F., Dinamik Sistemlerin Uyumlu Sinirsel-Bulanık Ağ Yapısına Dayalı Etkin Modellenmesi, KSÜ Fen ve Mühendislik Dergisi, 6(1): 36-46, 2003.
- [31] Jang, J.S.R, Sun, C.T. and Mizutani, E., Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence, Prentice Hall, N.J., 1997.
- [32] Caner M., Akarasslan E., Estimation of Specific Energy Factor in Marble Cutting Process Using ANFIS and ANN, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, Cilt 15, Sayı 2, Sayfa 221-226, 2009.
- [33] Perez, P., Prediction of sulfur dioxide concentration at a site near downtown santiago, chile, Atmospheric Envi-ronment. (35), 4929-4935, 2001.
- [34] Jang, J. S. R. ve Sun, C. T., Neuro-Fuzzy Modeling and Control. Proc. Of the IEEE Special Issue on Fuzzy Logic in Engineering Applications, 83 (3): 378-406, 1995.
- [35] Desbrandes, R., Theorie et interpretation des diagraphies. Editions Technip, Paris, 545p, 1968.

- [36] Ünalın, G., Kömür Jeolojisi, MTA Genel Müdürlüğü, Ankara, Turkey, p. 239-269, 2010.
- [37] Pekiner, Y., Kuyu Logları Tekniğıyle Yeraltının Keşfi, Ankara, Türkiye, 2002.
- [38] Ward, C.R., Coal Geology and Coal Technology. Blackwell Scienfic Publications, 345p, 1984.
- [39] Schlumberger, Log Interpretation. Volume 1-Principles, Schlumberger 1972 Edition, 113p, 1972.
- [40] Vessey, S. J. ve Bustin, R. M., Sedimentology of the coal bearing Mist Mountain Formation, Line Creek, Southern Canadian Cordillera; relationships to coal quality. Int. Journal of Coal Geology, 42, 129-158, 2000.
- [41] Rolon, L., Mohagheh, S. D., Ameri, S., Gaskari, R., McDaniel, B., Using artificial neural networks to generate synthetic well logs, Journal of Natural Gas Science and Engineering 1, 118–133, 2009.
- [42] Tan, T., Ertürk, İ., Pekmezci, F., Manisa-Soma-Eynez İzmir-Kınık-Yaylaköy Sahası 04.05.2009 Sözleşme Raporu: Mta Rap.No 11332, Ankara, Türkiye, 2010.
- [43] Ercan, T., Satır, M., Sevin, D. ve Türkecan, A., Batı Anadolu'daki Tersiyer ve Kuvaterner Yaşlı Volkanik Kayaçlarda Yeni Yapılan Radyometrik Yaş Ölçümlerinin Yorumu: MTA Derg. No 119,103-112, Ankara, Türkiye, 1997.
- [44] Kaya O., Ortadoğu Ege Çöküntüsünün (Neojen) Stratigrafisi ve Tektoniğı. Türkiye Jeol. Bült. No 22, 35-58, Ankara, Türkiye, 1979.

ÖZGEÇMİŞ

Hamza KARAMAN, 01.01.1981 de Tokat'ta doğdu. İlk, orta ve lise eğitimini Silivri'de tamamladı. 2000 yılında başladığı Cumhuriyet Üniversitesi Jeofizik Mühendisliği Bölümünden 2004'te mezun oldu. 2005 yılında Yertek Mühendislik Araş. ve Son. Tic. Ltd. Şti'de Jeofizik Mühendisi olarak çalıştı. 2006 yılı başında askerlik dönüşünde Maden Tetkik ve Arama Genel Müdürlüğü(MTA), Jeofizik Etütleri Dairesi Başkanlığında çalışmaya başladı. 2006-2014 yılları arasında Ankara'dan görevli olarak gittiği muhtelif illerde kömür, jeotermal, uranyum, bitümlü şeyl ve rejyonal jeofizik projelerinde kamp şefi ve teknik eleman olarak görev yaptı. 2014 yılında MTA İstanbul İrtibat Şube Müdürlüğü görevini yürüttü. 2015 yılı başından itibaren İstanbul(Tuzla) Deniz Araştırmaları Kamp Şefliğinde Kamp Şefi Yardımcısı olarak görev yapmaktadır.