

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

DALGA PARAMETRELERİNİN YAPAY ZEKA TEKNİKLERİ İLE TAHMİNİ

Serbay YÖNTEM

**YÜKSEK LİSANS TEZİ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

2016

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

DALGA PARAMETRELERİNİN YAPAY ZEKA TEKNİKLERİ İLE TAHMİNİ

Serbay YÖNTEM

**YÜKSEK LİSANS TEZİ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

Bu tez .../.../2016 tarihinde aşağıdaki jüri tarafından Oybirliği/Oyçokluğu ile kabul edilmiştir.

Yrd.Doç.Dr. Rıfat TÜR
Yrd.Doç.Dr. Tanju AKAR
Yrd.Doç.Dr. Alp KÜÇÜKOSMANOĞLU

ÖZET

DALGA PARAMETRELERİNİN YAPAY ZEKA TEKNİKLERİ İLE TAHMİNİ

SERBAY YÖNTEM

Yüksek Lisans Tezi, İnşaat Mühendisliği Anabilim Dalı

Danışman: Yrd.Doç.Dr. Rıfat TÜR

Temmuz 2016, 108 sayfa

Dalga yüksekliği parametrelerinin ($H_{1/3}$, $H_{1/10}$ vb.) doğru ve tutarlı olarak tahmin edilmesi kıyı yapıları tasarımında önem arz etmektedir. Yapının önem derecesi tasarımda kullanılacak olan dalga yüksekliği parametresini etkilemektedir. Bu çalışmada, Filyos Deniz Yöresi'nde ölçülmüş olan $H_{1/3}$, $H_{1/10}$, H_{ort} , H_{max} değerleri ve diğer dalga karakteristikleri kullanılarak dalga yüksekliği parametrelerinin tahmini için yapay zeka teknikleri (Yapay Sinir Ağları-Artificial Neural Networks-ANN, Uyarlamalı Ağ Temelli Bulanık Çıkarım Sistemi-Adaptive Neural Network Based Fuzzy Inference Systems-ANFIS) kullanılmıştır. Dalga yüksekliği parametrelerinin tahmininde her yapay zeka tekniği için alt modeller oluşturulmuştur. Akademik çalışmalarda sık kullanılan yapay zeka teknikleri söz konusu deniz yöresi için değerlendirilmiş ve dalga yüksekliği parametrelerinin tahmini için en uygun teknik belirlenmiştir. Söz konusu teknikler birbirleri ile karşılaştırılmış, avantajlı ve dezavantajlı yönleri değerlendirilmiştir. Sonuç olarak; dalga yüksekliği parametreleri tahmininde yapay zeka tekniklerinin geleneksel lineer regresyon, zaman serileri vb. yöntemlere göre daha tutarlı ve doğru sonuçlar ortaya koyduğu tespit edilmiştir. Aynı zamanda modellenen dalga yüksekliği parametreleri arasında karşılaştırma yapılmış ve bu parametrelerin hangi yapay zeka tekniği ile daha doğru sonuçlar verdiği saptanmıştır.

ANAHTAR KELİMELER: Dalga yüksekliği parametreleri, yapay sinir ağları, ANFIS, tahmin modeli, Filyos deniz yöresi.

JÜRİ: Yrd.Doç.Dr. Rıfat TÜR (Danışman)

Yrd.Doç.Dr. Tanju AKAR

Yrd.Doç.Dr. Alp KÜÇÜKOSMANOĞLU

ABSTRACT

FORECASTING WAVE PARAMETERS WITH ARTIFICIAL INTELLIGENCE TECHNIQUES

SERBAY YÖNTEM

MSc Thesis in Civil Engineering
Supervisor: Asst. Prof. Dr. Rifat TÜR
July 2016, 108 pages

It is important accuracy and forecasting of wave parameters ($H_{1/3}$, $H_{1/10}$ vb.) in design of coastal structures. Wave height parameter used in the design which determines structure's the degree of importance. In this study, using $H_{1/3}$, $H_{1/10}$, H_{ort} , H_{max} values and other wave characteristics that were measured at Filyos Sea Region, artificial intelligence techniques (Artificial Neural Networks-ANN, Adaptive Neural Network Based Fuzzy Inference Systems-ANFIS) were developed which forecasts wave height parameters. In estimation of wave height parameters, sub-models were created for each artificial intelligence technique. Commonly used artificial intelligence techniques in academic studies evaluated for that sea region and the most appropriate method is determined for forecasting wave parameters. These methods are compared with each other and evaluated advantages and disadvantages cases. As a result, artificial intelligence techniques were found to be far ahead compared to traditional methods in forecasting wave parameters. Therewithal, modeled wave height parameters compared between and it was determined that parameters gave more accurate results which model and techniques.

KEYWORDS: Wave height parameters, artificial neural networks, ANFIS, forecasting model, Filyos sea region.

COMMITTEE: Asst. Prof. Dr. Rifat TÜR (Supervisor)
Asst. Prof. Dr. Tanju AKAR
Asst. Prof. Dr. Alp KÜÇÜKOSMANOĞLU

ÖNSÖZ

Kıyı alanları bakımından zengin sayılabilecek coğrafyamızda dünya ile yarış içerisinde olabilmek için gerek ekonomik gerekse de çevresel etkenler açısından kıyı yapılarına önem gösterilmelidir. Bu yapıların tasarımında dalga parametreleri şüphesiz büyük öneme sahiptir. Kıyı yapılarının tasarımı ve boyutlandırılması için önemli bir yere sahip dalga parametrelerinin, yapılacak yapının türü, önemi ve boyutlarına göre uzun dönemli ölçümlerinin olması gerekmektedir. Fakat dalga parametrelerinin ölçümü hem aşırı zahmetli hem de maliyetlidir.

Bu sebeple elde bulunan az sayıda ölçüm değerlerinden, eksik olan değerlerin ve ileriye yönelik dalga parametrelerinin (dalga yüksekliği, periyodu vs.) tutarlı ve doğru tahmini büyük önem arz etmektedir. Bu çalışmanın amacı dalga parametrelerini son yıllarda geniş uygulama alanı bulan yapay zeka teknikleri (artificial intelligence techniques) ile modelleyerek en doğru tahmin sonuçlarına ulaşmaktır. Kıyı yapıları tasarımında yapıya gelecek dalga yüksekliğinin ve periyodunun doğru olarak belirlenmesi bu tip maliyetli yapılarda güvenilirlik ve ileride meydana gelebilecek hasarların önlenmesi açısından önem arz etmektedir.

T.C. Ulaştırma, Denizcilik ve Haberleşme Bakanlığı, Altyapı Yatırımları Genel Müdürlüğü'ne, Araştırma Dairesi Başkanlığı çalışanlarından Yüksek İnşaat Mühendisi Engin Bilyay ve Yüksek Jeoloji Mühendisi Aziz Ünal'a sağladıkları katkılardan dolayı teşekkür ederim. Ayrıca bana bu konuda çalışma olanağı veren ve çalışmamda destek olan danışmanım Sayın Yrd.Doç.Dr. Rıfat TÜR'e (*Akdeniz Üniversitesi, İnşaat Mühendisliği Bölümü, Hidrolik Ana Bilim Dalı*) saygılarımı ve teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	ii
ÖNSÖZ	iii
İÇİNDEKİLER	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ	1
2. KURAMSAL BİLGİLER VE KAYNAK TARMALARI.....	3
3. MATERYAL	7
3.1. Yapay Zeka Teknikleri.....	7
3.1.1. Genetik algoritmalar	8
3.1.2. Yapay sinir ağları	8
3.1.2.1. Yapay sinir ağlarının tarihsel gelişimi	9
3.1.2.2. Nöronun biyolojik yapısı ve nöron modeli	10
3.1.2.3. Yapay sinir ağlarının özellikleri.....	12
3.1.2.4. Yapay sinir ağlarının sınıflandırılması.....	13
3.1.2.5. Toplama fonksiyonu	19
3.1.2.6. Transfer fonksiyonları.....	20
3.1.2.7. Geçiş fonksiyonu.....	22
3.1.2.8. Yapay sinir ağlarının avantajları	23
3.1.2.9. Yapay sinir ağlarının dezavantajları	26
3.1.3. Bulanık mantık.....	27
3.1.3.1. Bulanık mantık gelişim süreci.....	27
3.1.3.2. Bulanık mantık kavramı.....	28
3.1.3.3. Bulanık kümeler.....	29
3.1.3.4. Bulanık kümelere temel işlemler	30
3.1.3.5. Üyelik fonksiyonu.....	32
3.1.3.6. Bulanık çıkarım işlemi	35
3.1.3.7. Durulaştırma yöntemleri	38
3.1.3.8. Bulanık mantığın avantaj ve dezavantajları	39
3.1.4. Bulanık sinir ağları (Neuro-Fuzzy).....	40
3.1.4.1. Mamdani bulanık – sinirsel modeli.....	41
3.1.4.2. ANFIS modeli (sugeno – takagi bulanık sinirsel modeli).....	42
3.2. Dalga İklimi ve Dalga İstatistiği	46
3.2.1. Giriş.....	46
3.2.2. Dalga iklimi ve istatistiği	47
3.2.3. Verilen bir konumda dalga şartları.....	50
3.2.4. Belirgin dalga yüksekliği ve diğer dalga parametreleri	51
4. METOT	53
4.1. Filyos Bölgesi	53
4.2. Araştırmanın Kapsamı ve Metodolojisi	55
4.3. Araştırma Verilerinin Analizi	55
4.3.1. Bulanık sinir ağları (ANFIS) ile modelleme.....	56
4.3.2. Yapay sinir ağları (ANN) ile modelleme	56
5. BULGULAR.....	57

5.1. ANFIS ile Modelleme Bulguları.....	56
5.1.1. H_s parametresi	61
5.1.2. $H_{1/10}$ parametresi	65
5.1.3. H_{ort} parametresi	70
5.1.4. H_{max} parametresi.....	74
5.2. ANN ile Modelleme Bulguları.....	78
5.2.1. H_s parametresi	82
5.2.2. $H_{1/10}$ parametresi	86
5.2.3. H_{ort} parametresi	90
5.2.4. H_{max} parametresi.....	94
6. TARTIŞMA VE SONUÇ	99
7. KAYNAKLAR	104
ÖZGEÇMİŞ	

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

e	Euler sayısı
f	Fonksiyon
μ	Üyelik derecesi
π	Pi sayısı
\cup	Birleşim
\cap	Kesişim
\subset	Kapsama
x, y	Değişkenler
\prod	Çarpım sembolü
\sum	Toplam sembolü
$\#$	Adet sembolü
H_s	Belirgin dalga yüksekliği
$H_{1/10}$	Dalgaların en yüksek %10'unun ortalaması
H_{ort}	Ortalama dalga yüksekliği
H_{max}	Maksimum dalga yüksekliği
T	Dalga periyodu
R^2	Korelasyon katsayısı

Kısaltmalar

ANFIS	Uyarlamalı ağ temelli bulanık çıkarım sistemi
ANN	Yapay sinir ağları
AR	Otoregresif
ARMA	Otoregresif hareketli ortalama
ARMAX	Hareketli çok değişkenli otoregresif model
ARX	Çok değişkenli otoregresif model
BD	Bayesian düzenleme
BP	Geri yayılım
BPM	Momentumlu geri yayılım
BPR	Esnek geri yayılım
CG	Eşleştirmeli gradyan azaltma geri yayılım
CORR.	Korelasyon katsayısı
FL	Bulanık mantık
MAE	Mutlak hata
MAX	Maksimum
MF	Üyelik fonksiyonu
MIN	Minimum
MLP	Çok katmanlı algılayıcı
RMSE	Ortalama hata karelerinin toplamının karekökü
TRA	Eğitim aşaması
TS	Takagi-sugeno

ŞEKİLLER DİZİNİ

Şekil 3.1. Yapay zeka teknikleri	8
Şekil 3.2. Basit bir nöron yapısı	11
Şekil 3.3. Sinir hücresinin matematiksel modeli.....	11
Şekil 3.4. ANN'nin genel blok şeması.....	11
Şekil 3.5. İleri beslemeli ANN yapısı	14
Şekil 3.6. Geri beslemeli ANN yapısı.....	14
Şekil 3.7. Genel bir ÇKP yapısı	15
Şekil 3.8. ANN'nin detaylı yapısı.....	16
Şekil 3.9. Keskin-limitli (hard-limit) transfer fonksiyonu	20
Şekil 3.10. Doğrusal (linear) transfer fonksiyonu.....	21
Şekil 3.11. Sigmoid transfer fonksiyonu.....	21
Şekil 3.12. Hiperbolik tanjant sigmoid fonksiyonu	21
Şekil 3.13. Değişik geçiş fonksiyonları.....	22
Şekil 3.14.a. Kesin kümelerin sınır gösterimi	29
Şekil 3.14.b. Bulanık kümelerin sınır gösterimi	29
Şekil 3.15. A kümesinin üyelik fonksiyonu	32
Şekil 3.16. Çeşitli üyelik fonksiyonu biçimleri.....	33
Şekil 3.17. Küme işlemlerinin üyelik fonksiyonları ile tanımlanması.....	34
Şekil 3.18. Üyelik fonksiyonunun öz, destek ve geçiş bölgeleri	35
Şekil 3.19. Genel bulanık mantık modeli.....	35
Şekil 3.20. Mamdani bulanık girişimli sistemi (T-norm ve S-norm operatörleri sırasıyla min ve max)	36
Şekil 3.21. Mamdani bulanık girişimli sistemi (T-norm ve S-norm operatörleri sırasıyla cebirsel çarpım ve max)	37

Şekil 3.22. Sugeno bulanık çıkarım metodu	38
Şekil 3.23. Mamdani bulanık-sinirsel sistem yapısı	41
Şekil 3.24. İki girişli ve dört kurallı bulanık Sugeno modelinin ANFIS yapısı.....	44
Şekil 3.25. 18 Şubat 1974'te OWS Hava Raportörlüğü'nün J istasyonunda kayıt edilen dalga profili	52
Şekil 4.1. Filyos deniz yöresi.....	53
Şekil 4.2. Filyos deniz yöresi ölçüm bölgesi	54
Şekil 5.1. H_s parametresi ANFIS analiz sistemi mimari yapısı	61
Şekil 5.2. Filyos Bölgesi H_s parametresi ANFIS 3D sistem analizi	62
Şekil 5.3. ANFIS Modeli H_s parametresi eğitim aşaması.....	63
Şekil 5.4. ANFIS Modeli H_s parametresi test aşaması	63
Şekil 5.5. H_s parametresi (ANFIS) eğitim aşaması saçılma diyagramı ve R^2 değeri.....	64
Şekil 5.6. H_s parametresi (ANFIS) test aşaması saçılma diyagramı ve R^2 değeri	65
Şekil 5.7. $H_{1/10}$ parametresi ANFIS analiz sistemi mimari yapısı.....	66
Şekil 5.8. Filyos Bölgesi $H_{1/10}$ parametresi ANFIS 3D sistem analizi.....	67
Şekil 5.9. ANFIS Modeli $H_{1/10}$ parametresi eğitim aşaması	67
Şekil 5.10. ANFIS Modeli $H_{1/10}$ parametresi test aşaması.....	68
Şekil 5.11. $H_{1/10}$ parametresi (ANFIS) eğitim aşaması saçılma diyagramı ve R^2 değeri	69
Şekil 5.12. $H_{1/10}$ parametresi (ANFIS) test aşaması saçılma diyagramı ve R^2 değeri....	69
Şekil 5.13. H_{ort} parametresi ANFIS analiz sistemi mimari yapısı	70
Şekil 5.14. Filyos Bölgesi H_{ort} parametresi ANFIS 3D sistem analizi	71
Şekil 5.15. ANFIS Modeli H_{ort} parametresi eğitim aşaması.....	72
Şekil 5.16. ANFIS Modeli H_{ort} parametresi test aşaması	72
Şekil 5.17. H_{ort} parametresi (ANFIS) eğitim aşaması saçılma diyagramı ve R^2 değeri .	73

Şekil 5.18. H_{ort} parametresi (ANFIS) test aşaması saçılma diyagramı ve R^2 değeri	73
Şekil 5.19. H_{max} parametresi ANFIS analiz sistemi mimari yapısı	74
Şekil 5.20. Filyos Bölgesi H_{max} parametresi ANFIS 3D sistem analizi	75
Şekil 5.21. ANFIS Modeli H_{max} parametresi eğitim aşaması	76
Şekil 5.22. ANFIS Modeli H_{max} parametresi test aşaması	76
Şekil 5.23. H_{max} parametresi (ANFIS) eğitim aşaması saçılma diyagramı ve R^2 değeri	77
Şekil 5.24. H_{max} parametresi (ANFIS) test aşaması saçılma diyagramı ve R^2 değeri....	77
Şekil 5.25. H_s parametresi Matlab ortamında oluşturulan ANN tabanı	82
Şekil 5.26. H_s parametresi ANN mimari yapısı	83
Şekil 5.27. H_s parametresi ANN eğitim grafiği	83
Şekil 5.28. ANN Modeli H_s parametresi eğitim aşaması	84
Şekil 5.29. ANN Modeli H_s parametresi test aşaması	84
Şekil 5.30. H_s parametresi (ANN) eğitim aşaması saçılma diyagramı ve R^2 değeri	85
Şekil 5.31. H_s parametresi (ANN) test aşaması saçılma diyagramı ve R^2 değeri	85
Şekil 5.32. $H_{1/10}$ parametresi Matlab ortamında oluşturulan ANN tabanı	86
Şekil 5.33. $H_{1/10}$ parametresi ANN mimari yapısı	87
Şekil 5.34. $H_{1/10}$ parametresi ANN eğitim grafiği	87
Şekil 5.35. ANN Modeli $H_{1/10}$ parametresi eğitim aşaması	88
Şekil 5.36. ANN Modeli $H_{1/10}$ parametresi test aşaması	88
Şekil 5.37. $H_{1/10}$ parametresi (ANN) eğitim aşaması saçılma diyagramı ve R^2 değeri..	89
Şekil 5.38. $H_{1/10}$ parametresi (ANN) test aşaması saçılma diyagramı ve R^2 değeri	89
Şekil 5.39. H_{ort} parametresi Matlab ortamında oluşturulan ANN tabanı	90
Şekil 5.40. H_{ort} parametresi ANN mimari yapısı	91
Şekil 5.41. H_{ort} parametresi ANN eğitim grafiği	91

Şekil 5.42. ANN Modeli H_{ort} parametresi eğitim aşaması.....	92
Şekil 5.43. ANN Modeli H_{ort} parametresi test aşaması	92
Şekil 5.44. H_{ort} parametresi (ANN) eğitim aşaması saçılma diyagramı ve R^2 değeri	93
Şekil 5.45. H_{ort} parametresi (ANN) test aşaması saçılma diyagramı ve R^2 değeri.....	93
Şekil 5.46. H_{max} parametresi Matlab ortamında oluşturulan ANN tabanı	94
Şekil 5.47. H_{max} parametresi ANN mimari yapısı	95
Şekil 5.48. H_{max} parametresi ANN eğitim grafiği.....	95
Şekil 5.49. ANN Modeli H_{max} parametresi eğitim aşaması	96
Şekil 5.50. ANN Modeli H_{max} parametresi test aşaması.....	96
Şekil 5.51. H_{max} parametresi (ANN) eğitim aşaması saçılma diyagramı ve R^2 değeri ..	97
Şekil 5.52. H_{max} parametresi (ANN) test aşaması saçılma diyagramı ve R^2 değeri.....	97
Şekil 6.1. ANFIS ve ANN, RMSE eğitim değerleri grafiksel gösterimi	100
Şekil 6.2. ANFIS ve ANN, RMSE test değerleri grafiksel gösterimi.....	100
Şekil 6.3. ANFIS ve ANN, MAE eğitim değerleri grafiksel gösterimi	101
Şekil 6.4. ANFIS ve ANN, MAE test değerleri grafiksel gösterimi.....	101
Şekil 6.5. ANFIS ve ANN, CORR. eğitim değerleri grafiksel gösterimi	102
Şekil 6.6. ANFIS ve ANN, CORR. test değerleri grafiksel gösterimi.....	103

ÇİZELGELER DİZİNİ

Çizelge 3.1. Bilgisayar ile insan beyni arasındaki çalışma yapısının karşılaştırılması.....	9
Çizelge 3.2. Bazı birleştirme fonksiyonları.....	19
Çizelge 3.3. Durulaştırma mekanizması tipleri.....	39
Çizelge 3.4. Durulaştırma mekanizmalarının matematiksel olarak ifadeleri.....	39
Çizelge 3.5. Bulanık mantık ve ANN açısından sistem modelleme adımları.....	45
Çizelge 3.6. Gelişmekte olan deniz durumu ve tam gelişmiş deniz durumu için belirgin dalga yüksekliği, dalga periyodu ve esme süresi	51
Çizelge 4.1. Oluşturulan zaman gecikmeli H_s model yapıları	55
Çizelge 5.1. H_s parametresi ANFIS modelleme sonuçları	57
Çizelge 5.2. $H_{1/10}$ parametresi ANFIS modelleme sonuçları	58
Çizelge 5.3. H_{ort} parametresi ANFIS modelleme sonuçları.....	59
Çizelge 5.4. H_{max} parametresi ANFIS modelleme sonuçları.....	60
Çizelge 5.5. H_s parametresi seçilen ANFIS modeli	62
Çizelge 5.6. H_s eğitim ve test aşaması ortalama hata oranları	64
Çizelge 5.7. $H_{1/10}$ parametresi seçilen ANFIS modeli	66
Çizelge 5.8. $H_{1/10}$ eğitim ve test aşaması ortalama hata oranları.....	68
Çizelge 5.9. H_{ort} parametresi seçilen ANFIS modeli	70
Çizelge 5.10. H_{ort} eğitim ve test aşaması ortalama hata oranları	73
Çizelge 5.11. H_{max} parametresi seçilen ANFIS modeli.....	75
Çizelge 5.12. H_{max} eğitim ve test aşaması ortalama hata oranları.....	77
Çizelge 5.13. H_s parametresi ANN modelleme sonuçları.....	78
Çizelge 5.14. $H_{1/10}$ parametresi ANN modelleme sonuçları	79
Çizelge 5.15. H_{ort} parametresi ANN modelleme sonuçları.....	80
Çizelge 5.16. H_{max} parametresi ANN modelleme sonuçları	81

Çizelge 5.17. H_s parametresi eğitim ve test aşaması hata oranları.....	85
Çizelge 5.18. $H_{1/10}$ parametresi eğitim ve test aşaması hata oranları.....	89
Çizelge 5.19. H_{ort} parametresi eğitim ve test aşaması hata oranları	93
Çizelge 5.20. H_{max} parametresi eğitim ve test aşaması hata oranları	97
Çizelge 6.1. Çalışmada kabul edilen yapay zeka metotları, model ve sonuçları	99

1. GİRİŞ

Kıyı alanları bakımından zengin sayılabilecek coğrafyamızda dünya ile yarış içerisinde olabilmek için gerek ekonomik gerekse de çevresel etkenler açısından kıyı yapılarına önem gösterilmelidir. Bu yapıların tasarımında dalga yüksekliği parametreleri şüphesiz büyük öneme sahiptir.

Dünya yüzeyindeki deniz ve göl kıyılarının değişik amaçlar için geniş ölçüde kullanıma açılması, bunun yanı sıra gelişen toplumların yarattığı çevre kirliliği sorunları kıyı mühendisliğini birçok değişik probleme karşı aynı ölçüde farklı çözümler üretmek zorunda bırakmıştır. Bunun sonucu olarak kıyı mühendisliğinde kullanılan yapıların hem çeşitleri hem de boyutlandırma kriterlerinde değişiklikler meydana gelmiştir (Kabdaşlı 1992).

Kıyı alanlarının çok değişik amaçlar için geniş ölçüde kullanıma açılması oluşan problemlerin farklı yöntemlerle çözümünü gerektirmektedir. Alınması gereken önlemler incelenecek olunursa; kıyı çizgisinin korunması, kıyı arkasının korunması, kıyı yapılarının oluşturulması başlıcalarıdır. Kıyı mühendisliği problemleri incelendiğinde büyük çoğunluğunun dalga ile ilişkisi açıkça görülür.

Kıyı yapılarının tasarımı ve boyutlandırılması için önemli bir yere sahip dalga karakteristiklerinin, yapılacak yapının türü, önemi ve boyutlarına göre uzun dönemli ölçümlerinin mevcut olması gerekmektedir. Fakat dalga karakteristiklerinin ölçümü hem aşırı zahmetli ve zaman alıcı hem de maliyetlidir. Bu sebeple elde bulunan az sayıda ölçüm değerlerinden, eksik olan değerlerin ve ileriye yönelik dalga karakteristiklerinin (dalga yüksekliği, periyodu vs.) tutarlı ve doğru tahmini büyük önem arz etmektedir. Bu çalışmanın amacı dalga yüksekliği parametrelerini son yıllarda geniş uygulama alanı bulan yapay zeka teknikleri ile modelleyerek en doğru tahmin sonuçlarının belirlenmesidir. Kıyı yapıları tasarımında yapıya gelecek dalga yüksekliğinin ve periyodunun doğru olarak belirlenmesi bu tip maliyetli yapılarda güvenilirlik ve ileride meydana gelebilecek hasarların önlenmesi açısından önem arz etmektedir.

Yapay sinir ağları ve bulanık mantık teknikleri, Hidrolik ve Kıyı Mühendisliği problemlerinde son yıllarda geniş kullanım alanı bulmuştur. Yapay sinir ağlarının temeli (ANN, Artificial Neural Networks) insandaki sinir hücrelerinin yaptığı işi bilgisayar ortamında taklit etmeye dayanmaktadır. Bu modelde temel amaç canlılardaki çalışma, öğrenme, karar verme, esneklik ve yeni duruma adaptasyon özelliklerini modellemeye çalışmaktır.

Bulanık mantık (FL, Fuzzy Logic) da yapay sinir ağları gibi insan beyninin çalışma mantığına dayanmaktadır. Kullanılan matematiğin basit olması, doğrusal olmayan sistemleri modelleyebilme yeteneği, günlük dile dayalı olması, esnek olması ve kesin olmayan bilgiye karşı toleranslı olması bulanık mantığa dayalı sistemlerin kullanımının getirdiği en önemli avantajlar arasındadır.

Uyarlamalı Ağ Temelli Bulanık Çıkarım Sistemi (ANFIS, Adaptive Network-based Fuzzy Inference System) yöntemi ise, ANN ve FL yöntemlerinin avantajlı yönlerinin kombine olarak kullanıldığı bir yöntemdir.

Bu tez çalışmasında, Filyos Deniz Yöresinde ölçülmüş olan dalga yüksekliği parametreleri ($H_{1/3}$, $H_{1/10}$, H_{ort} , H_{max}), ANN ve ANFIS teknikleri ile tahmin edilmiş ve elde edilen değerler gerçek değerler ile karşılaştırılmıştır. Her iki teknik için oluşturulan modeller sayesinde eksik veya yanlış verilerin tamamlanması ve ileriye yönelik dalga yüksekliği parametrelerinin tahmini yapılabilmektedir.

2. KURAMSAL BİLGİLER VE KAYNAK TARAMALARI

Bir çok mühendislik dalında olduğu gibi İnşaat Mühendisliği alanında da yapay zeka teknikleri geniş uygulama alanı bulmaktadır. Özellikle son yıllarda yapay zeka teknikleri yüksek derecede belirsizlik içeren problemlerin çözümünde klasik yöntemlere iyi bir alternatif oluşturmaktadır. Yapay zeka tekniklerinin geneline bakıldığında uygulamada en çok karşılaşılan yöntemler yapay sinir ağları, bulanık mantık ve genetik algoritmalarıdır. Diğer yöntemlere kıyasla daha az uygulama alanı bulan genetik algoritmalar genelde atık su ve kanalizasyon şebekelerinin tasarımında ve optimizasyonunda yaygın olarak kullanılmaktadır.

Yapay sinir ağları ve bulanık mantık yöntemlerine bakıldığında ise en çok uygulama hidrolik anabilim dalında yapılmıştır. Özellikle geçmiş gözlem verilerine dayanan hidroloji ve kıyı mühendisliği konularında tahmin amaçlı birçok model geliştirilmiştir. Elde edilen sonuçlar özellikle tahmin modelleri dikkate alındığında söz konusu yeni yöntemleri tahmin tutarlılığı açısından destekler yöndedir.

Genellikle çalışmalar elde edilen tahmin verilerinin, sahada ölçülmüş gerçek veriler ile karşılaştırılması şeklindedir. Literatürde, karşılaştırma işlemi anlamlı kılan çeşitli istatistiksel performans parametreleri mevcuttur. Bunlardan en sık kullanılanları arasında, Ortalama Hata Karelerinin Toplamının Karekökü (RMSE, Root Mean Square Error), Ortalama Bağlı Hata (MAE, Mean Absolute Error) ve Korelasyon Katsayısı (R^2 , Correlation Coefficient) bulunmaktadır. Çalışmalarda istatistiksel performans parametrelerinin sonuçları en uygun modelin seçiminde anahtar rol oynamaktadır (Nayak ve Sudheer 2008).

RMSE: Her veri noktası ile model arasında birbirine uymayan noktaların ortalama oranıdır. Hataların karesinin ortalaması alındıktan sonra karekökü alınarak bulunur (Eşitlik 2.1).

$$RMSE = \left[\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \right]^{0.5} \quad (2.1)$$

MAE: Her bir hata değerini pozitif yapmak için hatanın mutlak değeri alınır, bunlar toplanır ve ortalaması alınır (Eşitlik 2.2). Hataların birbirini yok etmemesi için böyle bir yöntem kullanılmaktadır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (2.2)$$

R^2 : Korelasyon, iki veya daha fazla değişken arasında bir ilişki olup olmadığını, eğer ilişki varsa bu ilişkinin miktarını ve yönünü sayısal olarak belirlememizi sağlayan istatistiksel bir tekniktir. İki değişken arasındaki ilişkinin derecesine ise korelasyon katsayısı denir (Eşitlik 2.3).

$$R^2 = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{n \sum x_i^2 - (\sum x_i)^2} \sqrt{n \sum y_i^2 - (\sum y_i)^2}} \quad (2.3)$$

Agrawal ve Deo (2002), ileri beslemeli yapay sinir ağı ve zaman serileri analizi kullanmışlar ve 3, 6, 12 ve 24 saatlik zaman aralıkları ile H_s (Belirgin Dalga Yüksekliği =Significant Wave Height= $H_{1/3}$) tahmin etmişlerdir. Tahmin modelleri $R^2=0.68-0.96$ aralığındadır.

Akpınar vd (2014), Karadeniz'in güney kıyılarında bulanık çıkarım sistemi ve parametrik modeller kullanarak dalga parametreleri tahmini yapmışlardır. Tahmin modellerinde zaman gecikmeli rüzgar verilerini kullanmışlar, ANFIS modelinde $R^2=0.66$, $MAE=0.37$, parametrik metot da ise $R^2=0.63$, $MAE=0.75$ bulmuşlar ve bulanık çıkarım sisteminin daha doğru sonuçlar verdiğini ortaya koymuşlardır.

Altunkaynak ve Wang (2012), genetik algoritma ve yapay sinir ağları kullanarak H_s tahmin modeli kurmuşlar ve çalışmalarında Florida Okeechobee Gölü'nde 4 ayrı istasyondan alınan verileri kullanmışlardır. Sonuç olarak genetik algoritma modelinin yapay sinir ağı modelinden daha tutarlı sonuçlar verdiğini ve daha düşük hata oranlarına sahip olduğunu göstermişlerdir.

Balas vd (2004), çalışmalarında yapay sinir ağlarını eksik dalga verilerinin tahmini için kullanmışlardır. İleri beslemeli çok katmanlı olan sinir ağlarını AR ve ARX gibi stokastik yöntemler ile karşılaştırmışlar ve yapay zeka metotlarının daha iyi performans gösterdiğini belirlemişlerdir. Çalışma eksik veya hatalı verilerin olduğu ölçüm durumlarında tutarlı çözümler sunmaktadır.

Balas ve Tür (2006), bulanık mantık yöntemi ile Mersin Limanı'nın elleçleme kapasitesini tahmin etmişlerdir. Yükleme ve boşaltma miktarları ayrı ayrı modellenip toplam elleçleme miktarı tahmin edilmiş ve korelasyon değerleri 0.83 ve 0.74 olarak bulunmuştur. Ayrıca liman için gelecek 23 yıl için ileri beslemeli yapay sinir ağları ile kapasite tahmini yapmışlardır.

Deka ve Prahlada (2012), yapay sinir ağları tekniğini hem tek başına hem de dalgacık dönüşümü uygulayarak kullanmışlardır. Hindistan'ın batı kıyısında 3, 6, 12, 24 ve 48 saat zaman aralıkları ile H_s tahmini gerçekleştirmişlerdir. Her iki algoritma için de çeşitli varyasyonlar denemişler ve dalgacık dönüşümlü yapay sinir ağı metodunun önerilen modellerde daha iyi sonuçlar verdiğini göstermişlerdir.

Deo ve Naidu (1999), çalışmalarında ANN ve AR ile H_s tahmin etmişlerdir. Çalışmaları sonucunda ANN'nin istatistiksel yöntemlere göre daha iyi sonuçlar verdiği görülmektedir. Geliştirilen model 3 ila 24 saatlik zaman aralıkları ile dalga yüksekliğini tahmin edebilmektedir.

Dixit vd (2015), Amerika kıyı bandında bulunan 3 istasyondan alınan veriler ile belirgin dalga yüksekliği tahmini yapmışlar ve ANN ve Neuro-Wavelet (dalgacık dönüşümlü yapay sinir ağları) tekniklerini kullanmışlardır. Çalışmalarını 12, 24 ve 36 saat zaman aralıkları için gerçekleştirmişlerdir. En tutarlı sonuçları 12 saat zaman aralığı için yapılan çalışmada almışlar ve ANN için $R^2=0.94$, Neuro-Wavelet için $R^2=0.98$

bulmuşlardır. Çok yüksek korelasyon değerlerine ulaşan bu çalışma dalgacık dönüşümlü modelin üstünlüğüne dikkat çekmektedir.

Gaur ve Deo (2008), Meksika körfezinde 2 istasyondan alınan veriler ile belirgin dalga yüksekliği tahmini yapmışlardır. Alınan verileri 15 yıllık bir periyoda aittir. 3, 6 ve 12 saatlik zaman dilimleri için tahmin gerçekleştirmişlerdir. Tahmin modellerini yapay zeka tekniklerinden genetik algoritmaların bir uzantısı olan genetik programlama ile oluşturmuşlardır. En doğru sonuçlara 3 saatlik zaman dilimi için yapılan çalışmada ulaşılırken, modellerin tutarlılığı zaman dilimi aralığı arttıkça azalmaktadır. En yüksek $R^2=0.97$ bulunurken bu modelde $RMSE=0.16$, $MAE=0.07$ bulunmuştur.

Kamranzad vd (2011), öğrenme metodu olarak ANN kullanmışlar ve 3, 6, 12 ve 24 saatlik zaman aralıkları için dalga yüksekliği tahmini yapmışlardır. Girdi parametresi olarak rüzgar hızı ve yönü, dalga yüksekliği kullanmışlardır. Çalışmaları sonucunda ANN ile lineer regresyon metodunu karşılaştırmışlardır. Zaman aralıkları arttıkça tutarlılığın azaldığını göstermişler ve en tutarlı sonuçları 3 saatlik zaman aralığı için bulmuşlardır. Sonuç olarak ANN metodunda $R^2=0.91$ ve $RMSE=0.012$, lineer regresyon metodunda ise $R^2=0.89$ ve $RMSE=0.014$ değerlerine ulaşmışlardır.

Makarynsky vd (2005), Portekiz'in batı kıyılarında yaptıkları bu çalışmada yapay sinir ağlarını kullanmışlar ve 3 farklı algoritma denemişlerdir. H_s , 3, 6, 12 ve 24 saat zaman aralıkları ile modellenmiştir. En tutarlı model $R^2=0.96$ ve hata oranı $RMSE= 0.17$ değerlerine ulaşmışlardır.

Mandal ve Prabakaran (2006), H_s parametresi tahmini için bir geri yayımlı yapay sinir ağları tekniği olan NARX (Nonlinear Autoregressive with eXogeneous inputs) kullanmışlardır. 3, 6 ve 12 saatlik zaman dilimleri için tahmin gerçekleştirilmiştir. Sırası ile R^2 değerleri 0.95, 0.90 ve 0.87 olarak bulunmuş 3 saatlik zaman diliminin en tutarlı sonuçları verdiği görülmüştür.

Nitsure vd (2012), bir yapay zeka tekniği olarak genetik programlama kullanmışlardır. Kuzey Amerika ve Hindistan kıyı şeritlerindeki meteoroloji istasyonlarından alınan rüzgar verileri ile H_s parametresinin tahmin etmişlerdir. 12 ve 24 saatlik zaman aralıkları ile gerçekleştirilen bu tahmin modellerinde ortalama korelasyon değeri $R^2 =0.88$ bulunmuştur.

Özger (2010), 4 değişik metot ile belirgin dalga yüksekliği tahmini yapmıştır. WFL=Wavelet Fuzzy Logic, FL, ANN, ARMA=Autoregressive Moving Average metotları kullanılmıştır. 3, 6, 12, 24 saat zaman aralıkları ile tahmin gerçekleştirmiştir. En tutarlı sonuçların alındığı 3 saat zaman aralığında gerçekleştirilen tahmin modelleri için korelasyon değerlerini sırasıyla 0.98, 0.93, 0.93, 0.93 bulmuştur. Çalışmada dalgacık dönüşümlü modelin daha iyi sonuçlar verdiği dikkati çekmektedir.

Özger ve Şen (2007), rüzgar hızı ile dalga yüksekliği arasındaki ilişkileri incelemişlerdir. Yapay zeka modeli olarak bulanık mantık temelli Takagi-Sugeno (TS) metodunu kullanmışlardır. Giriş parametresi olarak rüzgar hızı ve geçmiş H_s değerlerini kullanmışlar ve 1, 3, 6 ve 12 saatlik zaman dilimleri için H_s tahmin etmişlerdir. Aynı zamanda çalışmalarını geleneksel bir yaklaşım olan ARMAX metodu ile de

gerçekleştirmişler ve bu metotların karşılaştırmasını yapmışlardır. Bulanık mantık çıkarımlı modellerin daha tutarlı sonuçlar verdiğini göstermişlerdir.

Tür ve Balas (2010), yapay sinir ağları ve bulanık mantık yöntemlerinin bir arada kullanıldığı neuro-fuzzy yöntemi ile belirgin dalga yüksekliği tahmin etmişlerdir. 5 adet zaman gecikmeli model oluşturulmuş ve en tutarlı sonucu veren model belirlenmiştir. Bu modelde korelasyon değerini 0.84 bulmuşlardır. Modellerin eksik dalga verilerinin tahmin edilmesinde verimli olarak kullanılabilceği sonucuna ulaşmışlar ve ayrıca model ileriye yönelik tahmin de gerçekleştirmektedir.

Tsai vd (2002), rüzgar verilerinden dalga verilerine geçilmesinin tahmin tutarlılığını azalttığını öne sürerek çalışmalarında ölçülmüş dalga verilerini kullanmışlardır. Kısa dönemli H_s ve T_s tahmini yapmışlar ve bunun için geri yayımlı ANN kullanmışlardır. Fakat bu parametrelerin tahmininde girdi olarak H_s , $H_{1/10}$, H_{ort} , H_{max} , T_s , $T_{1/10}$, T_{ort} , T_{max} değerlerini kullanmışlardır. En tutarlı modellerinde H_s için $R^2=0.96$, T_s içinse $R^2=0.88$ değerlerine ulaşmışlardır.

Vimala vd (2014), Bengal Körfezi'nden 2003-2004 yılları arasında alınmış olan dalga parametreleri verilerini kullanarak belirgin dalga yüksekliği tahmin etmişlerdir. Tahminlerini 3, 6, 12 ve 24 saat zaman aralıkları için yapmışlardır. Çalışmaları için yapay sinir ağları tekniğini ve bu teknik için giriş parametresi olarak rüzgar hızı veya dalga yüksekliği kullanmışlardır. Eğitim aşamasında Ocak 2003-Aralık 2003, test aşamasında ise Temmuz 2004-Kasım 2004 verilerini kullanmışlardır. En yüksek korelasyon değerlerine 3 saatlik zaman aralığı için ulaşılmış, giriş parametresi olarak rüzgar hızının kullanıldığı modelde $R^2 = 0.92$, dalga yüksekliğinin kullanıldığı modelde ise $R^2 = 0.98$ bulunmuştur. Dolayısıyla H_s tahmin modellerinde direkt dalga yüksekliği verilerinin rüzgar hızı verileri kullanımından daha tutarlı sonuçlar verdiğini göstermişlerdir.

Wang ve Ding (2003), yeni bir hibrit model olan dalgacık dönüşüm analizi destekli yapay sinir ağı kullanmışlar ve bu modelin hidrolojide uygulamalarını ortaya koymuşlardır. Yeraltı suyu seviyesi ve günlük deşarj miktarları tahmininde bu modeli kullanmışlardır.

Zamani vd (2008), rüzgar hızı ile dalga yüksekliği arasındaki ilişkiyi ortaya koyarak dalga yüksekliği tahmini yapmışlardır. Bir ileri beslemeli ANN tekniği olan MLP (multilayer perceptron) kullanmışlardır. Çalışmalarını 3, 6, 12 ve 24 saatlik zaman dilimleri ile gerçekleştirmişler ve en verimli durumda $R^2 = 0.91$ bulmuşlardır. Hata oranını $RMSE = 0.16$ hesaplamışlar ve ANN'nin diğer yöntemlerden daha etkin olduğunu göstermişlerdir.

Ayrıca literatürde dalga parametrelerinin yapay zeka teknikleri ile tahmin edildiği birçok çalışma mevcuttur: Elmdoust ve Kerachian (2012), Günaydın (2008), Hadadpour vd (2014), Huang (2004), Londhe (2008), Londhe ve Panchang (2007), Makarynsky (2004), Malekmohamadi vd (2011), Zanaganeh (2009).

3. MATERYAL

3.1. Yapay Zeka Teknikleri

“**Zeka**, karmaşık bir problemi gerekli bilgileri toplayıp, derleyip, bunlara bağlı olarak çözüm arama alanlarını daraltarak, problemi en kısa yoldan çözüme kabiliyetidir.” (Lenat ve Feigenbaum 1991).

Yapay zeka konusundaki araştırmalarıyla tanınmış iki ünlü bilim insanlarından D.Lenat ve E.Feigenbaum “zeka” kelimesinin tanımını arama alanı ve bilgi kullanımı kavramlarına bağlı kalarak yukarıdaki gibi tarif etmişlerdir.


Genel olarak **Zeka**, beynin öğrenme, anlama, soyut düşünme, sebeplendirme, planlama, problem çözüme gibi zihinsel işlevlerine verilen isimdir. Canlıların; karşılaştıkları sorunları zeka yardımıyla çözebilmesi planlama yapması, olaylar karşısında sebeplendirme ilişkisi kurabiliyor olması bilim insanlarını bu kontrol ve uygulama mekanizmasını teknolojiye aktarmaya yönlendirmiştir. Bunun sonucu olarak “Yapay Zeka” adı verilen sistemler ortaya çıkmıştır.

Yapay zeka, insanlarda zeka ile ilgili zihinsel fonksiyonları bilgisayar modelleri yardımıyla inceleyip bunları formel hale getirdikten sonra yapay sistemlere uygulamayı amaçlayan bir araştırma alanıdır.

Yapay zekanın amaçları ;

- 1) İnsan beyninin fonksiyonlarını bilgisayar modelleri yardımıyla anlamaya çalışmak.
- 2) İnsanların sahip olduğu zihinsel yetenekleri, bilgi kazanma, öğrenme ve buluş yapmada uyguladıkları strateji, metot ve teknikleri araştırmak.
- 3) Bu öğrenme metotlarını biçimsel hale getirmek ve bilgisayarlarda bilgi sistemleri halinde uygulamak.
- 4) İnsanların bilgisayar kullanımını kolaylaştıracak insan/bilgisayar ara birimleri geliştirmek.
- 5) Belli bir uzmanlık alanı içindeki bilgileri bir bilgi sistemi (veya uzman sistem) halinde toplamak.
- 6) Geleceğin bilgi toplumunun kurulmasında önemli rol oynayacak genel bilgi sistemleri geliştirmek.
- 7) Yapay zeka iş yardımcıları ve zeki robot timleri geliştirmek.
- 8) Bilimsel araştırma ve buluşlarda faydalanmak üzere, ‘araştırma yardımcıları’ geliştirmek.

Yapay zeka teknikleri genel olarak 3 ana gruba ayrılmıştır (Şekil 3.1);



Şekil 3.1. Yapay zeka teknikleri

3.1.1. Genetik algoritmalar

Genetik algoritmalar, Darwin' in doğal seçim ve evrim teorisi ilkelerine dayanan bir arama ve optimizasyon yöntemidir.

Bu yöntem ilk olarak, John Holland ve arkadaşlarının yaptığı çalışmalarda 1975'te ortaya çıkmıştır (Holland 1975). Ön bilgi ve varsayımlar olmadan, sadece uygunluk fonksiyonu ile çalışabilmektedir.

3.1.2. Yapay sinir ağları

Yapay sinir ağları, zaman serilerinin tahmini, regresyon analizi, optimizasyon ve sınıflandırma işlemleri gibi değişik alanlarda uygulanmaya başlanan lineer olmayan bir yapay zeka tekniğidir. Yapay sinir ağları, yapay sinir hücrelerinin katmanlar şeklinde bağlanmasıyla oluşturulan veri tabanlı sistemler olup insan beyninin öğrenme ve değişik koşullar altında çok hızlı karar verebilme gibi yeteneklerinin, basitleştirilmiş modeller yardımıyla karmaşık problemlerin çözülmesinde kullanılmasını amaçlamaktadır. Sınıflandırma, kümeleme, regresyon ve zaman serilerinin tahmini gibi değişik alanlarda kullanılan yapay sinir ağları uygulamalarının en büyük avantajı, karmaşık modellere gereksinim duyulmaksızın yalnızca ağın eğitilmesi yoluyla problemlere çözüm getirebilmesidir. Bu sebepten dolayı yapay sinir ağları ile çözüm yapılırken, bulanık mantığın tersine kural tabanının oluşturulması sırasında bir uzman öngörüsüne gereksinim kalmamaktadır.

Yapay sinir ağları ya da kısaca ANN; insan beyninin çalışma sisteminin yapay olarak benzetimi çabalarının bir sonucu olarak ortaya çıkmıştır. En genel anlamda bir ANN insan beynindeki birçok nöronun (sinir hücresinin), ya da yapay olarak basit işlemcilerin birbirlerine değişik etki seviyeleri ile bağlanması sonucu oluşan karmaşık bir sistem olarak düşünülebilir. Önceleri temel tıp birimlerinde insan beynindeki nöronların matematiksel modelleme çabaları ile başlayan çalışmalar, geçtiğimiz on sene içerisinde, disipline bir şekil almıştır. ANN bugün fizik, matematik, elektrik ve bilgisayar mühendisliği gibi çok farklı bilim dallarında araştırma konusu haline gelmiştir. ANN'nin pratik kullanımı genelde, çok farklı yapıda ve formlarda bulunabilen enformasyon verilerini hızlı bir şekilde tanımlama ve algılama üzerinedir. Aslında mühendislik uygulamalarında Yasa'nın geniş çaplı kullanımının en önemli nedeni, klasik tekniklerle çözümü zor problemler için etkin bir alternatif oluşturmasıdır. Çünkü

bilgisayarlar insanın beyinsel yeteneğinin en zayıf olduğu çarpma, bölme gibi matematiksel ve algoritma hesaplama işlemlerinde hız ve doğruluk açısından yüzlerce kat başarılı olmalarına rağmen insan beyninin öğrenme ve tanıma gibi işlevlerini hala yeteri kadar gerçekleştirememektedir. Çizelge 3.1’de bilgisayar ile insan beyni arasındaki çalışma sistem yapısı karşılaştırmalı olarak verilmiştir.

Çizelge 3.1. Bilgisayar ile insan beyni arasındaki çalışma yapısının karşılaştırılması

BİLGİSAYAR	İNSAN BEYİNİ
Sayısal	Analog
Seri	Paralel
Komut	Bilgiye Adapte Olma
Yanlış Hesaplamalar Sonucu Etkiler	Birimlerin Ana İşlemlere Etkisi Azdır
Giriş Verilerindeki Hatalar Sonucu Etkiler	Giriş Verilerindeki Hatalara Her Zaman Duyarlı Değil

Yapay sinir ağları insan beyninin öğrenme, düşünme ve değişik koşullar altında çok hızlı karar verebilme gibi yeteneklerinin basitleştirilmiş modeller yardımıyla kompleks problemlerin çözülmesinde kullanılmasını amaçlamaktadır ve kullanım amaçlarına göre değişik tiplerde yapay sinir ağları bulunmaktadır. Sınıflandırma, kümeleme, modelleme ve tahmin gibi değişik işlemlerde kullanılan yapay sinir ağlarının (Kalagirou 1999) en büyük avantajları doğrusal olmayan sistemleri modelleyebilmesi; bilgiyi paralel olarak işleyebilmesi ve yeni durumlara uyum sağlayabilme yeteneği olarak verilebilir. Yapay sinir ağları genel olarak ağ yapısına göre ileri beslemeli ve geri beslemeli yapay sinir ağları; eğitme algoritmalarına bağlı olarak ise denetimli ve denetimsiz yapay sinir ağları olarak sınıflandırılabilir. İleri beslemeli denetimli yapay sinir ağları en yaygın kullanılan yapay sinir ağlarıdır (Svozil vd. 1997).

3.1.2.1.Yapay sinir ağlarının tarihsel gelişimi

İnsan davranışlarını taklit etmek amacıyla geliştirilen yapay zekâ uygulamalarının bir alt dalı olan yapay sinir ağları, ortaya çıkışından günümüze değin birçok aşamalardan geçmiş ve son yıllardaki teknolojik gelişime paralel olarak gelişimini çok hızlı bir şekilde devam ettirmektedir. Yapay sinir ağlarının tarihçesi nörobiyoloji konusuna insanların ilgi duyması ve elde ettikleri bilgileri bilgisayar bilimine uygulamaları ile başlamaktadır. Yapay sinir ağları ile ilgili çalışmaları 1970 öncesi ve sonrası diye ikiye ayırmak gerekmektedir. Çünkü 1970 yılında bu bilimin tarihinde bir önemli dönüm noktası başlamış ve o zamana kadar olmaz diye düşünülen birçok sorun çözülmüş ve yeni gelişmeler başlamıştır. Her şey bitti derken yapay sinir ağları yeniden doğmuştur.

1943 yılında McCulloch ve Pitts’in yayınladıkları makale yapay sinir ağları konusundaki ilk makale sayılmaktadır (McCulloch ve Pitts 1943). Bu makalede sinirlerin giriş faaliyet seviyesi, belirli bir eşik değerine eriştiğinde aktif hale geçen açık/kapalı anahtar gibi davrandıklarını ve mantık fonksiyonlarını hesaplamak için çeşitli şekillerde bir araya getirilebileceklerini göstermiştir. 1949’da nöropsikolog Hebb yayınladığı makalede beynin öğrenme yeteneğini bir modelle açıklamıştır (Hebb 1949).

“Hebbian öğrenme” kuralı denilen bu kural günümüzde de birçok öğrenme kuralının temelini oluşturmaktadır. 1954’te M. Minsky yapay sinir ağları konusunda doktora yapmış ve 1960’lı yıllarda yapay sinir ağlarına ilgi büyük ölçüde artmıştır. Bu yıllarda F. Rosenblatt, McCulloch ve Pitts’in eşik değeri yaklaşımını kullanarak tecrübeye dayanan, öğrenebilen eleman ağlarını meydana getirmiştir. Yine bu yıllarda S. Grossberg, verbal öğrenmede deney sonuçlarıyla ifade edilen ağların diferansiyel denklemlerini kurmuş; daha sonra gerçek biyolojik sinir ağlarını ifade eden genel denklem setini çıkarmış ve yaptığı araştırmaların sonunda “Adaptif Rezonans Teorisi”ni geliştirmiştir. 1969 yılında M. Minsky ve S. Papert yapay sinir ağlarındaki sınırlamaları inceledikleri “perceptrons” adlı kitabı yayınlamışlardır (Minsky ve Paperts 1972). Bu kitapta tek katmanlı ağların “ayrıcılık veya” işlemini gerçeklemek gibi basit sorunları çözemeyecekleri ispatlanmıştır.

Yapay sinir ağlarındaki büyük gelişmeler 1980’li yıllarda gerçekleşmiştir. 1980’lerin başında J. Hopfield, gelişmeyle birlikte rasgele bulunan etkenlerin probleme karıştığını ve her çözüm yolunda problemin başlangıç halinde bulunduğu işaret etmiş, bu nedenle her hesaplamının doğru çözüm yolu için sürekli yenilenen bir mekanizmaya ihtiyaç olduğunu belirterek bu iş için geliştirdiği stratejiyi yapay sinir ağlarında kullanmıştır. 1986 yılında D. Rummelhart, G. Hinton ve R. Williams geriye yayılım öğrenme kuralıyla çok tabakalı ağ sistemlerinin birçok problemi çözmek için eğitilebileceğini göstermiştir (Hopfield ve Tank 1986). Son yıllarda bilgisayar teknolojisindeki büyük gelişmelerden dolayı, yapay sinir ağlarının yazılım ve donanım uygulamaları hızla devam etmektedir.

Günümüzde yapay sinir ağları artık teorik ve laboratuvar çalışmaları olmaktan çıkmış ve günlük hayatta kullanılan sistemler oluşturmaya ve pratik olarak insanlara faydalı olmaya başlamışlardır.


3.1.2.2. Nöronun biyolojik yapısı ve nöron modeli

Haykin (1994) ANN'yi şöyle tanımlar:


‘Yapay sinir ağı; deneyime dayalı bilgiyi depolamaya ve bu bilgiyi kullanıma sunmaya yönelik doğal bir eğilim içinde olan yoğun paralel dağıtılmış bir işlemcidir. ANN iki açıdan insan beynine benzemektedir: Bilgi ağ tarafından bir öğrenme süreci aracılığı ile elde edilmektedir ve sinir hücreleri arasında snaptik ağırlık olarak adlandırılan bağlar bilgiyi depolamakta kullanılmaktadır.’

Biyolojik sinir ağlarının temel elemanı sinir hücreleridir ve insan beyninin korteks kısmında yer alan nöron (sinir hücresi) sayısı yaklaşık olarak 10^{11} olup her hücre sayısı, 1,000-10,000 arasında değişen başka hücrelerle karşılıklı ilişki içerisindedir. Bir sinir hücresinin temel elemanları hücre gövdesi, dendrit ve akson’dur (Harvey 1994). Sinir hücresine (Şekil 3.2) diğer sinir hücrelerinden gelen uyarımlar, dendritler aracılığıyla hücre gövdesine taşınır ve hücre içi aktivasyonun/kararlılık halinin bozulmasıyla oluşan bir kimyasal süreç içerisinde diğer hücelere aksonlarla iletilir; uyarımların diğer sinir hücrelerine taşınabilmesinde akson uçları ile dendritler arasındaki sinaptik boşluklar (sinaps) rol oynar. Sinaptik boşluk içinde yer alan “sinaptik kesecikler” gelen uyarımların diğer hücelere dendritler aracılığıyla geçmesini koşullayan elemanlardır. Sinaptik boşluğa, “sinaptik kesecikler” tarafından sağlanan nöro-iletken maddenin dolması

uyarımların diğer hücelere geçişini koşullar. Hücelere gelen uyarımlarla uyumlu olarak hücreler arasındaki mevcut sinaptik ilişkilerin değişimi veya hücreler arasında yeni sinaptik ilişkilerin kurulması “öğrenme” sürecine karşılık gelir. Şekil 3.3'te en basit formda gösterilen nöron modeli, bir eşik birimi olarak algılanabilir.




Şekil 3.2. Basit bir nöron yapısı



Şekil 3.3. Sinir hücresinin matematiksel modeli

Basit bir ANN yapısı aşağıdaki gibi özetlenebilir (Şekil 3.4);



Şekil 3.4. ANN'nin genel blok şeması

Eşik birimi, çıkışları toplayan ve sadece girişin toplamı iç eşik değerini aştığında bir çıkış üreten işlem elemanıdır. Bir eşik birimi olarak nöron sinapslarındaki işaretleri alır ve hepsini toplar. Eğer toplanan işaret gücü eşiği geçecek kadar güçlü ise diğer nöronları ve dendritleri uyaran akson boyunca bir işaret gönderilir. Kesişen dendritlerden gelen sinapslarla kapılanan bütün işaretleri soma toplar. Toplam işaret daha sonra nöronun iç eşik değeri ile karşılaştırılır ve eşik değerini aşmışsa aksona bir işaret yayar. ANN, bu basit nöronların (düğümün ya da ünitelerin) bağlanarak bir ağa dönüştürülmesiyle meydana getirilir.

3.1.2.3. Yapay sinir ağlarının özellikleri

ANN'lerin en önemli özellikleri; öğrenme, genelleme yapabilme, doğrusal olmama, gürültüyü yayabildiklerinden dolayı gürültüye karşı tolerans, paralel işlem yapabilme, donanım olarak gerçekleştirilebilme ve uyarlanabilirliktir (Elmas 2007).

❖ Doğrusal olmama

ANN'nin temel işlem elemanı olan nöron doğrusal olmak zorunda değildir. Bu durumda hücrelerin birleşmesinden meydana gelen ANN'de doğrusal olmayacaktır. Bu yüzden, ANN doğrusal olmayan karmaşık problemlere kolayca çözüm getirebilmektedir.

❖ Öğrenme

Bir sistemin girişi ve çıkışı arasındaki ilişkiyi en iyi tanımlayacak olan ANN ağırlıklarının bulunması işlemine öğrenme denir. Bu işlemde ANN yapısı üzerindeki ağırlıkların bir öğrenme algoritması kullanılmasıyla, istenilen bağıntıyı öğrenmesi sağlanır. Bu nedenle ANN, istenen davranışı gösterecek şekilde ilişkilendirmek istenen sistemin uygun örnek giriş ve çıkışlarından faydalanılarak gerçekleştirilir.

❖ Genelleme yapabilme

ANN bir problemi öğrendikten sonra eğitimde kullanılmayan test verileri içinde beklenen veya istenilen tepkiyi üretme kabiliyetine sahiptir. Nöral hesaplamada hafızalar birleşiktir. Yani eğitilmiş ağırlıklara giriş örneğinin bir kısmı verilse bile, ağırlıklardan bu girişe en yakını seçerek uygun çıkış değeri üretir. ANN'ye bozuk veya eksik bir bilgi verilse bile ağırlıklar kabul edilebilir en uygun çıkışı verecektir. Burada temel özellik az veriyle sistem davranışının veya ilişkisinin öğrenilmesidir.

❖ Uyarlanabilirlik

ANN'nin ağırlıkları, problemden probleme değişir. Yani bir problemde iyi çıkışlar veren ağırlıklar diğer bir problem için iyi çıkışlar vermeyebilir. ANN problemlerdeki değişimlere göre farklı şekilde eğitilebilirler. Bu özellik ANN ile hedef tanıma ve izleme, uyarlamalı örnek tanıma, sınıflandırma, görüntü ve sinyal işleme, otomatik sistem kimliklendirme ve kontrol gibi alanlarda kullanım kolaylığı sağlamaktadır.

❖ Donanım Olarak gerçekleştirilebilme

ANN paralel işlem yapabilme yetenekleri nedeni ile büyük ölçekli entegre devre (VLSI-Very Large Scale Integration) teknolojisiyle tarafından desteklenmektedirler. Bu özellikleri ile de ANN en ileri düzeydeki veri işleme teknolojileri arasındadır. Bu nedenle hızlı işlem yapabilme kabiliyetine sahiptirler.

❖ **Hataya karşı duyarlılık**

ANN çok sayıda işlemci elemandan oluşmuştur. Bu elemanlar arası bağlantılar paralel dağıtılmış bir yapıya sahiptir. Ağın sahip olduğu bilgi, ağdaki bütün bağlantılara dağıtılmıştır. Giriş veri setinde bulunabilecek herhangi bir gürültü, bütün ağırlıklar üzerine dağıtıldığından dolayı, gürültü etkisi tolere edilebilir. Geleneksel yöntemlere göre hatayı tolere etme yetenekleri daha fazladır.

❖ **Veri işleme**

Biyolojik sistemlerde veri dağınık yapıda saklanır. Yapay sinir ağlarında ise veriler ağırlıklar üzerine dağıtılmıştır. Ağırlıklar herhangi bir anda ANN'nin problemiyle ilgili olarak sahip bulunduğu bilgiyi ifade eder. Yapay sinir ağlarında veri ağırlıklar üzerine paralel olarak dağıtılmış şekilde temsil edilmekte, korunmakta ve işlenmektedir. ANN'de dağıtılmış birleşik hafıza yapısı kullanılır.

3.1.2.4. Yapay sinir ağlarının sınıflandırılması

ANN işlemci eleman olarak adlandırılan nöronlardan ve ağ bağlantılarından oluşmaktadırlar. Bu nedenle ağ bağlantı şekillerine, öğrenme kuralları ve transfer fonksiyonlarına göre belirlenen bu ANN modellerini yapılarına ve öğrenme algoritmalarına bağlı olarak sınıflandırmak mümkündür.


❖ **Yapay sinir ağlarının ağ yapılarına göre sınıflandırılması**

ANN mimari yapılarına göre ileri beslemeli (feed-forward) ve geri beslemeli (feed-back) ağlar olarak ikiye ayrılabilir. Bu yapılar aşağıdaki kısımlarda açıklanmıştır.

➤ **İleri beslemeli ağ yapısı**

İleri beslemeli bir ağda işlemci elemanlar katmanlar üzerinde bulunur. Giriş katmanı, dış ortamdaki aldığı bilgileri hiçbir değişiklik yapmadan ara katmandaki işlemci elemanlara iletir. Bilgi, ara katman veya katmanlarla çıkış katmanında işlenerek ağ çıkışına iletilir. Girişler tek yönlü olarak çıkışa doğru iletilirken, her bir katman çıkışı diğer katmana giriş olarak uygulanmaktadır. Herhangi bir andaki çıkış değeri, sadece o andaki girişin fonksiyonu şeklinde ortaya çıkmaktadır. Böylece bu ağ yapısı, statik yapı bir hafızaya sahip olur (Elmas, 2007).


İleri beslemeli ağlar doğrusal olmayan bir yapıya sahip olup çok katmanlı perseptronlar (ÇKP), LVQ (Learning Vector Quantization-Nicemleme Öğrenme Vektörü) ağ yapıları bunlara örnek olarak verilebilir. ÇKP yapısının eğitilmesinde en çok kullanılan öğrenme algoritması geri yayılım algoritmasıdır. İleri beslemeli ANN yapısı Şekil 3.5'te verilmiştir.



Şekil 3.5. İleri beslemeli ANN yapısı

➤ Geri beslemeli ağ yapısı

Geri beslemeli bir sinir ağı, en az bir işlemci eleman çıkışının kendisine veya diğer işlemci elemanlara bir gecikme elemanı üzerinden giriş olarak uygulanması ile elde edilen ağ yapısıdır. Geri besleme, bir katmandaki işlemciler arasında olduğu gibi katmanlar arasındaki işlemciler arasında da gerçekleştirilebilmektedir. Geri beslemeli ANN yapıları, doğrusal olmayan dinamik bir davranış gösterirler ve herhangi andaki çıkış değeri hem o andaki hem de daha önceki giriş değerlerine sahiptirler. Dinamik yapılarından dolayı geri beslemeli ANN tahmin uygulamalarında başarılı bir şekilde kullanılmaktadırlar. Şekil 3.6'da geri beslemeli bir ANN yapısı verilmiştir (Elmas, 2007).




Şekil 3.6. Geri beslemeli ANN yapısı

❖ Yapay sinir ağı yapıları

Literatürde çok sayıda ANN ağ yapısı bulunmaktadır. Bunlara, ÇKP'ler, LVQ'lar, Elman ve Jordan Ağları, Radyal Tabanlı Yapay sinir ağı yapıları örnek olarak verilebilir. Bu ağlardan en çok kullanılan ÇKP aşağıda anlatılmıştır.

➤ Çok katmanlı perseptron ANN yapısı



Şekil 3.7. Genel bir ÇKP Yapısı

Çok katmanlı bir perseptron sinir ağı modeli, Şekil 3.7’de gösterilmiştir. Bu ağ modeli özellikle mühendislik uygulamalarında en çok kullanılan sinir ağı modeli olmuştur. Bu modelin yaygın kullanılmasının sebebi, bir çok öğrenme algoritmasının bu ağın eğitiminde kolaylıkla kullanılabilmesidir.

Bu model yapay sinir ağının öğrenmesi istenen olayların girdi ve çıktıları arasındaki ilişkilerin doğrusal olmadığı durumlarda, ağın olayları öğrenebilmesi için kullanılan gelişmiş modellerden biridir. Rumelhart vd. (1986) tarafından geliştirilen bu modele hata yayma modeli veya geriye yayım modeli (backpropagation network) de denilmektedir. Özellikle sınıflandırma, tanıma ve genelleme yapma gerektiren problemlerde başarı ile uygulanmıştır. Bu modelin Temel amacı ağın beklenen çıktısı ile ürettiği çıktı arasındaki hatayı en aza indirmektir. Bu olayı gerçekleştirirken hata ağı yayıldığından ve ağa hata yayma ağı da denilmektedir (Cangir 2008).

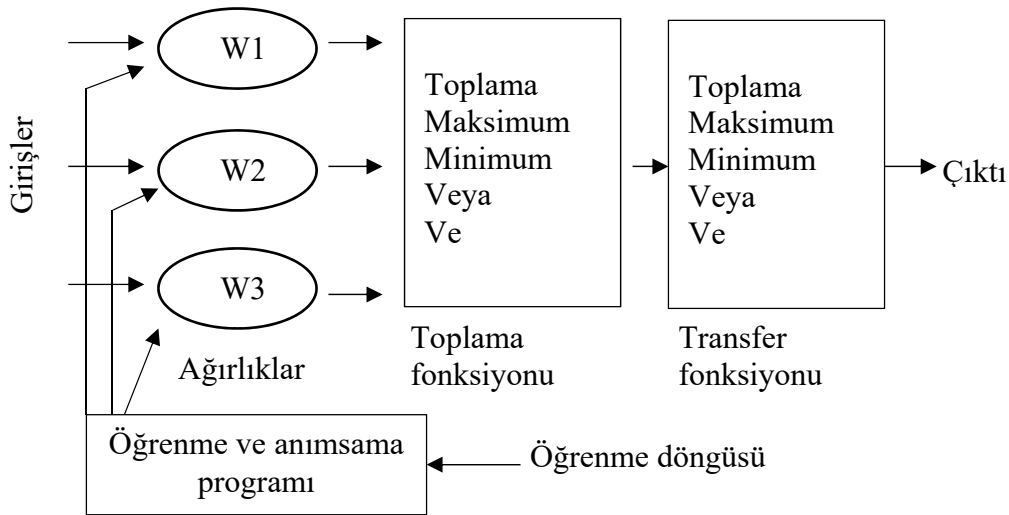
➤ ÇKP modelinin yapısı

Bir nöron genellikle, eş zamanlı birçok sayıda girdi alır. Her girdinin kendi nispi ağırlığı vardır. Bu ağırlıklar, biyolojik nöronların değişen sinaptik etkililikleri ile aynı görevi üstlenirler. Her iki durumda da, bazı girdiler diğerlerine göre daha önemli hale gelirler. Bu sayede, işlem elemanının bir sinirsel tepki üretmesi işleminde daha fazla etkili olurlar. Ayrıca, ağırlıklar girdi sinyalinin güçlülüğünü belirleyen adaptif katsayılarıdır. Yani, girdinin bağlantı gücünün bir ölçüsüdür. Bu bağlantı güçleri, çeşitli eğitim setlerine göre değiştirilebilirler. Şekil 2.8’de, yapay nöronun detaylı bir şeması sunulmaktadır. Şekilde, girdi değerler işlem elemanına üst sol bölümden girmektedir. İşleminde ilk adım, bu girdi değerlerin her birinin ilgili ağırlıklarla $w(i)$ ağırlıklandırılmaktadır (Yurtoğlu 2005).

Ağırlıklandırılmadan sonra, bu değiştirilmiş girdiler toplama fonksiyonuna gönderilirler. Toplama fonksiyonunda, adından da anlaşılacağı gibi, genelde toplama işlemi yapılmaktadır fakat birçok farklı işlem çeşidi toplama fonksiyonu için kullanılabilir. Toplama fonksiyonu, bu basit çarpımlar toplamına ek olarak, minimum,

maksimum, mod, çarpım veya çeşitli normalizasyon işlemlerinden birisi olabilir. Girdileri birleştirecek olan algoritma genellikle seçilen ağ mimarisine de bağlıdır. Bu fonksiyonlar farklı şekilde değerler üretebilir ve sonra bu değerler ileri doğru gönderilir. Ek olarak, uygulamacı kendi fonksiyonunu oluşturup toplama fonksiyonu olarak kullanabilir. Bazı toplama fonksiyonları, transfer fonksiyonuna ilemeden önce, sonuçları üzerinde ilave işlemler yaparlar. Bu işlem aktivasyon fonksiyonu olarak adlandırılan işlemdir. Bir aktivasyon fonksiyonu kullanmanın amacı toplama fonksiyonu çıktısının zamana bağlı olarak değişmesini sağlamaktır. Fakat aktivasyon fonksiyonu literatürü henüz tam olarak gelişmemiştir. Bundan dolayı, çoğu yapay sinir ağında birim aktivasyon fonksiyonu kullanılmaktadır. Birim aktivasyon fonksiyonu ise bir aktivasyon fonksiyonu kullanılmaması ile aynı anlama gelmektedir. Ayrıca, aktivasyon fonksiyonu, her işlem birimi için ayrı ayrı kullanılan bir bileşenden ziyade ağın genel bir bileşenidir. Yani, oluşturulan bir ağ yapısında, tüm işlem elemanları aynı aktivasyon fonksiyonunu kullanırlar (Cangir 2008).

Sonraki aşamada toplama fonksiyonunun çıktısı transfer fonksiyonuna gönderilir. Bu fonksiyon, aldığı değeri bir algoritma ile gerçek bir çıktıya dönüştürür. Transfer fonksiyonu genellikle doğrusal olmayan bir fonksiyondur. Doğrusal fonksiyonlar genelde tercih edilmez çünkü doğrusal fonksiyonlarda çıktı, girdi ile orantılıdır. Bu durum, ilk ANN denemelerinin başarısızlıkla sonuçlanmasının temel nedenidir (Minsky ve Papert 1969). Genellikle kullanılan transfer fonksiyonları eşik, sigmoid, hiperbolik tanjant vb. fonksiyonlardır. Bu fonksiyonlar arasında en çok kullanılanlar Şekil 3.8’de örneklenmiştir. Transfer fonksiyonunun sonucu genellikle işlem elemanının çıktısıdır. Transfer fonksiyonu, toplama fonksiyonundan gelen ve şekilde ‘Toplam’ olarak gösterilen değeri alır ve “0” ile “1” arasında bir değere dönüştürür. Sıfır ile bir arasındaki bu değer transfer fonksiyonunun ve dolayısıyla işlem elemanının çıktısıdır ve dış ortama veya girdi olarak başka bir nörona iletilir.



Şekil 3.8. ANN'nin detaylı yapısı (Yurtoğlu 2005)

❖ Yapay sinir ağlarının öğrenme algoritmalarına göre sınıflandırılması

Öğrenme; gözlem ve eğitim sonucu oluşan hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanabilir. Bu tanıma göre, ANN’de öğrenme yani gözlem ve eğitim sonucu oluşan davranış değişiklikleri, bir takım metot ve kurallar yardımıyla ağırlıkların değiştirilmesiyle sağlanabilir. Öğrenme sırasında, ağın uyarılması sonucunda ağırlıklarında uyarılması ve ağın problemi çözmeye yönelik yeni tepkiler vermesi gerekir.

Literatürde, ANN yapılarına göre farklılık gösteren ve aşağıdaki bölümlerde kısaca anlatılan çok sayıda öğrenme algoritması mevcuttur (Sağiroğlu vd. 2003).

➤ Geri Yayılım (BP)

Bir çok uygulamada yaygın bir şekilde kullanılmakta olan bir öğrenme algoritmasıdır. Anlaşılması ve matematik olarak kolayca ispatlanabilir olmasından dolayı tercih edilmektedir. Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır.

➤ Momentumlu Geri Yayılım (BPM-Back Propagation Momentum)

Momentum ağı lokal gradyanleri aşmasını sağladığı gibi aynı zamanda hatanın hızlı düşmesine de yardımcı olur. Bir alçak geçiren süzgeç gibi davranan momentum, ağı hata yüzeyindeki küçük değerlerin ihmal edilebilmesini sağlar. Momentum olmaksızın ağ lokal bir minimuma takılarak salınımlar yapabilir. Momentum kullanılır ise ağ lokal minimumun diğer yüzüne sıçrama imkanı kazanır.

➤ Esnek Geri Yayılım (BPR-Back Resillient Propagation)

Sinir düğümü yapısında sıklıkla sigmoid tabanlı fonksiyonlar kullanılır. Bu fonksiyonlar sonsuz giriş aralığındaki veriyi sonlu aralığa transfer ederler ve giriş değeri büyüdükçe fonksiyonlardaki eğiklik sifıra doğru gider. Bu durum sigmoid fonksiyonlarına sahip sinir ağlarında türevdeki değişikliklerin parametre üzerindeki etkisini azaltır. Bu yüzden türevin değeri yerine yalnızca işaretine göre parametrelerin yenilenmesini sağlamak amacıyla bu yöntem geliştirilmiştir. Bu yöntem önceki anlatılan yöntemden daha hızlı yakınsamaktadır.

➤ Eşleştirmeli Gradyan Azaltma Geri Yayılım (CG-Conjugate Gradien)

Basit geri-yayılım algoritması ağırlık değerlerini gradyanın negatif yönünde dengeler. Bu doğrultu gradyanın hızla düştüğü doğrultu olarak bilinir. Bu doğrultuda performans fonksiyonu da hızla düşer. Performans fonksiyonundaki hızlı düşüşe rağmen bu gelişme sonuca en hızlı yakınsama için gerekli olmayabilir. Eşleştirmeli gradyan algoritmalarında hızlı gradyan düşüş doğrultusundan genellikle daha çabuk sonuca yakınsayan eşleştirme doğrultusunda bir arama işlemi uygulanır. Bir çok eşleştirmeli gradyan algoritmasında adım boyutu her bir iterasyonda yeniden düzenlenir. Performans fonksiyonunun yakınsama doğrultusu boyunca minimize edilmesi için güncelleme adım

boyutunun belirlenmesi amacıyla eşleştirmeli gradyan doğrultusu boyunca bir arama gerçekleştirilir.

➤ **Quasi-Newton (QN)**

Newton yöntemleri hızlı optimizasyon için kullanılacak yöntemlerdir. QN eşleştirmeli gradyan yöntemlerine göre çok daha fazla hafıza ve her iterasyonda çok daha fazla hesaplama gerektirse de genellikle birkaç iterasyonda sonuca erişir. Küçük boyutlu ağlarda kullanımı daha uygundur.

➤ **Delta-Bar-Delta (DBD)**

Bir ÇKP öğrenme algoritması olan DBD'nin eğitme kuralı, ağırlıkların yakınsama hızını arttırmak için kullanılan sezgisel bir yaklaşımdır. DBD öğrenme algoritmasında, ağırlık her bir bağlantısına atanan öğrenme katsayılarının optimum değerlerinin belirlenmesi çok zor ve zaman alıcı olabilmektedir. Bu algorithmada, bir bağlantıya ait ağırlık değişim işaretinin ardışık birkaç adımı sırasıyla farklı değerler alması durumunda öğrenme oranı azaltılmalı aynı kalması durumunda ise öğrenme oranı artırılmalıdır. Bu değişimi sağlayabilmek için ağırlıklar, hatanın derecesine bağlı olan kısmi türevlerine ve ağırlık değeri noktasının çevresindeki hata yüzeyinin eğrilik ölçüsüne göre güncellenmelidir.

➤ **Genişletilmiş Delta-Bar-Delta (EDBD-Extended Delta-Bar-Delta)**

Bu algoritma isminden de anlaşılacağı gibi Jacobs tarafından sunulan DBD algoritmasının geliştirilmiş halidir. DBD algoritmasından farklılıkları; sezgisel momentum kullanması, ağırlık uzayında büyük artmaları ortadan kaldırması ve geometrik azaltımın büyük orandaki atlamalarını engellemede yeterince hızlı olmaları şeklinde sıralanabilir.

➤ **Levenberg Marquardt (LM)**

Oldukça başarılı bir optimizasyon metodu olan LM algoritması, öğrenmede kullanılan geri yayılım algoritmasının farklı öğrenme tekniklerinden birisidir. Bu öğrenme algoritmasının seçilmesinin sebebi, hızlı öğrenme ve iyi yakınsayabilme özelliğinden kaynaklanmaktadır. Temel olarak LM algoritması, maksimum komşuluk fikri üzerine kurulmuş bir hesaplama metodu olup Gauss-Newton ve Steepest-Descent (adım azaltmalı) algoritmalarının en iyi özelliklerinden oluşmuştur ve bu iki metodun kısıtlamalarını ortadan kaldırmaktadır. Performans fonksiyonu kareler toplamı biçimine sahip olduğunda Hessian matrisine;

$$H=J^T J \quad (3.1)$$

şeklinde yaklaşıklık yapılabilir ve buradan gradyan;

$$g=J^T .e \quad (3.2)$$

olarak hesaplanabilir. Eşitliklerde, J ağda yer alan ağırlık ve biaslara (yanlılık) ait hataların ilk türevlerini içeren Jacobiyen matrisidir. e ise, ağ hatalarının vektörüdür. T matris transpozmesini temsil eder. Bu metot ile performans fonksiyonu algoritmanın her iterasyonunda azalan bir eğim gösterecektir ve J matrisini Hessian matrisi yerine kullanır:

$$w_{k+1} = w_k - [J^T \cdot J + \mu I]^{-1} J^T \times e \quad (3.3)$$

Eğer μ büyük ise, minimum yaklaşım adımı küçük olur. Bu yüzden, her başarılı adımda μ değeri azaltılmalıdır. Eğer performans fonksiyonu artıyorsa μ artırılmalıdır.

➤ Bayesian Düzenleme (BD) Öğrenme Algoritması

Optimum düzenleme parametrelerinin otomatik bulunması arzu edilir. Bu amaçla kullanılan yöntemlerden biri Bayesian düzenleme yaklaşımıdır. Bayesian yaklaşımının ağda bulunan ağırlıklar ve bias değerleri, farklı dağılımlı değişkenler gibi düşünülür. Düzenleme parametreleri bu dağılımların birleşiminin değeri bilinmeyen varyansı ile ilişkilendirilerek tahmin edilir. Bu amaçla istatistiksel yöntemler kullanılır.

3.1.2.5. Toplama fonksiyonu

Bir ANN'de, girdi birimi olmayan her bir nöron bağlantılar yardımı ile diğer nöronlardan gelen değerleri toplar ve net girdiyi üretir. Diğer nöronlardan gelen değerleri toplayan bu fonksiyona, toplama (birleştirme) fonksiyonu denir. Birçok ANN'de, her bir nöronun bağlantılı olduğu diğer nöronun girdisine ek bir katkıda bulunduğu varsayılır. Herhangi bir j nöronunun toplam girdisi, diğer nöronlardan gelen değerlerin ağırlıklı toplamı ile eşik (bias) değerinin toplamına eşittir (Küçük ve Ayvaz 2013).

$$a_j = \sum_i w_{ji} x_i + \theta_j \quad (3.4)$$

Yukarıdaki fonksiyona toplam fonksiyonu denir. Toplam fonksiyonundan başka kullanılan birleştirme fonksiyonları da vardır. En çok kullanılan birleştirme fonksiyonları Çizelge 3.2'de gösterilmiştir.

Çizelge 3.2. Bazı birleştirme fonksiyonları

Toplam	$a_j = \sum_i w_{ji} x_i$	Çarpım	$a_j = \prod_i w_{ji} x_i$
Maksimum	$a_j = \text{Maks} (w_{ji} x_i)$	Minimum	$a_j = \text{Min} (w_{ji} x_i)$
Çoğunluk	$a_j = \sum_i \text{Sgn} (w_{ji} x_i)$		

x_i = i nöronunun çıktısı

w_{ji} = j ve i nöronları arasındaki bağlantının ağırlığı

a_j = j nöronunun net girdisi

3.1.2.6. Transfer fonksiyonları


ANN nöronları; transfer fonksiyonu adı verilen fonksiyonlar içerirler. Gradyan azaltımında kullanılan asıl fonksiyonlar transfer fonksiyonlarıdır. Transfer fonksiyonları öğrenme eğrisi veya aktivasyon fonksiyonu olarak da adlandırılmaktadır.

Aktivasyon fonksiyonu sinir hücresinin davranışını belirleyen temel özelliklerden biridir. Her bir sinir hücresi bir aktivasyon fonksiyonuna sahiptir. Sinir hücresine gelen giriş bilgileri, bağlantı ağırlıklarıyla çarpılıp toplanarak aktivasyon fonksiyonundan geçirilir. Aktivasyon fonksiyonundan geçirilir. Aktivasyon fonksiyonu çıkış bilgilerinin normalize edilmesi ve lineerlik ve nonlineerlik kazandırılması açısından önem taşır. Aktivasyon fonksiyonunun modeli sinir ağı sistemindeki istenilen çıkış sinyali tipinde seçilen bir fonksiyondur. Sinir ağındaki farklı sinir hücrelerinin sahip oldukları aktivasyon fonksiyonları farklı olabilir. Bu fonksiyonlar, hücreye gelen net girdiyi işleyerek bu girdiye karşılık üreteceği çıktıyı belirlerler. Çok katmanlı algılayıcılar için bu fonksiyonun türevlenebilir olması şarttır. Bir nöronun çıkışı hesaplanırken çok çeşitli transfer fonksiyonları kullanılabilir (Küçük ve Ayvaz 2013).

Doğrusal olmayan transfer fonksiyonlarının da kullanılması ile yapay sinir ağları daha karmaşık problemlere uygulanmaya başlanmıştır. En çok kullanılan 4 transfer fonksiyonu aşağıda verilmiştir (Cangir, 2008).

❖ Keskin-Limitli (Hard-Limit) Transfer Fonksiyonu


Keskin-limitli (hard-limit) transfer fonksiyonunun grafiği Şekil 3.9'da verilmiştir. Burada, s fonksiyonun girişi, a ise çıkışıdır: $a=f(s)$. Bu fonksiyonda, giriş değeri 0 (sıfır)'dan büyükse çıkış değeri 1 (bir), giriş değeri 0 (sıfır)'dan küçükse çıkış değeri 0 (sıfır) olmaktadır. Genelde sınıflandırma uygulamalarında kullanılmaktadır.



Şekil 3.9. Keskin-limitli (hard-limit) transfer fonksiyonu

❖ Doğrusal (Linear) Transfer Fonksiyonu


Doğrusal (linear) transfer fonksiyonunun grafiği Şekil 3.10'da verilmiştir. Görüldüğü gibi giriş hiçbir değişikliğe uğramadan aynen çıkmaktadır ($a=f(s)$). Doğrusal süzgeç problemlerinde sıklıkla kullanılmaktadır.



Şekil 3.10. Doğrusal (linear) transfer fonksiyonu

❖ Sigmoid Transfer Fonksiyonu


Sigmoid fonksiyonunun grafiği Şekil 3.11’de verilmiştir. Sigmoid, doğrusal olmayan (non-linear) logaritmik bir fonksiyondur. Giriş değerleri hangi aralıkta olursa olsun, çıkış 0 ile 1 arasında olmaktadır. Türevlenebilir olduğu için geriye yayılım algoritmaları ile kullanılabilir. Doğrusal olmayan problemlerin çözümünde tercih edilmektedir. Matematiksel ifadesi şu şekildedir:



Şekil 3.11. Sigmoid transfer fonksiyonu

❖ Hiperbolik Tanjant Sigmoid Fonksiyonu

Hiperbolik tanjant sigmoid fonksiyonunun grafiği Şekil 3.12’de verilmiştir.



Şekil 3.12. Hiperbolik tanjant sigmoid fonksiyonu

3.1.2.7. Geçiş fonksiyonu


Toplam fonksiyonu bir neuron'un ne düzeyde uyarılacağını belirleyen bir fonksiyondur. Bir neuronun hangi uyarılma düzeyinden sonra çıktı ($j y$) üreteceği ve çıktının uyarılma düzeyi ile ilişkisi ise, geçiş fonksiyonu tarafından belirlenmektedir (Vemuri 1992).

$$f(j a) = j y \quad (3.5)$$

Bu ilişki çıktının hangi aralıklarda olacağını belirlemesi açısından da önemlidir (Vemuri 1992). Çünkü toplam fonksiyonu tarafından üretilen değer oldukça büyük olabilir ve değer çıktı için kullanıldığında, birkaç katman sonra çıktı değeri çok büyük değerlere ulaşacağı için çıktının 0, 1 veya bazen -1, +1 aralığına dönüştürülmesi gerekmektedir (Trippi ve Lee 1996).

Geçiş fonksiyonu olarak sıklıkla kullanılan fonksiyonlar aşağıda listelenmiştir:

- İkili (binary) veya eşik fonksiyonu (Şekil 3.13.a)
- Doğrusal fonksiyon (Şekil 3.13.b)
- Sigmoid fonksiyon (Şekil 3.13.c)
- Hiperbolik tanjant fonksiyonu (Şekil 3.13.d)'dur.



Şekil 3.13. Değişik geçiş fonksiyonları

İkili adım fonksiyonunda çıktı değerinin (y_j) oluşması için girdi değerinin belli bir (T) değerine ulaşması gerekmektedir. (T) değerinden önce çıktı "0" iken, bu değerden sonra çıktı "1" değerini alır (Şekil 3.13-a).

Doğrusal geçiş fonksiyonunda Çıktı=Girdi olurken, adımli doğrusal geçiş fonksiyonunda T eşik değeri aşıldıktan sonra $y_j = \text{Girdi} - T$ şeklinde olmaktadır (Şekil 3.13-b).

En çok kullanılan geçiş fonksiyonu sigmoid fonksiyondur. Sigmoid fonksiyonunun en önemli özelliği girdinin tüm değerleri için 0-1 arasında bir değer üretmesidir (Şekil 3.13-c). Sigmoid fonksiyonu;

$$y_j = \frac{1}{1+e^{-y_j}} \quad \text{veya} \quad y_j = \frac{1}{1+e^{-y_j \cdot c}} \quad \text{'dir} \quad (3.6)$$

şeklinde ifade edilir.

Bu formülde c öğrenme oranı olarak bilinen ve değeri sistem tasarımcısı tarafından belirlenen bir katsayı olup sigmoid fonksiyonun "0" noktasına olan eğimini belirler. Söz konusu c değeri yükseldikçe sigmoid fonksiyon orjine keskin adımlarla yaklaşır (Rojas, 1996).

Sigmoid fonksiyonun biraz farklı şekli hiperbolik tanjant fonksiyonudur. Sigmoid fonksiyondan farkı, fonksiyonun çıktılarının -1 ve +1 arasında değerler almasıdır (Şekil 3.13-d).

Hiperbolik tanjant fonksiyonu;

$$y_j = \frac{e^u - e^{-u}}{e^u + e^{-u}} \quad (3.7)$$

şeklinde ifade edilir. Burada $u = y \cdot c \cdot j$ 'dir.

Geçiş fonksiyonu çıktı olarak sadece 0-1 den oluşan ikili değerler alabileceği gibi 0 ile 1 veya -1 ile +1 arasında sürekli değer de alabilir. Ayrıca sistemin parametrelerinden olan eşik değerinin (T) ve c 'nin (kazanç katsayısı olarak da bilinmektedir) ne olacağı ağı tasarlayan tasarımcıya bağlıdır (Zahedi, 1991).

3.1.2.8. Yapay sinir ağlarının avantajları

Yapay sinir ağları makine öğrenmesi gerçekleştirirler: Yapay sinir ağlarının temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar. Geleneksel programlama ve yapay zekâ yöntemlerinin uygulandığı bilgi işleme yöntemlerinden tamamen farklı bir bilgi işleme yöntemi vardır.

- ✓ **Bilginin saklanması:** Yapay sinir ağlarında bilgi, ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi veriler bir veri tabanında veya programın içinde gömülü değildir. Bilgiler ağın üzerinde saklı olup ortaya çıkartılması ve yorumlanması zordur.

- ✓ **Yapay sinir ağları örnekleri kullanarak öğrenirler:** Yapay sinir ağlarının olayları öğrenebilmesi için o olay ile ilgili örneklerin belirlenmesi gerekmektedir. Örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneğe kavuşturulurlar (adaptif öğrenme). Örnek bulunamıyorsa veya yok ise yapay sinir ağının eğitilmesi mümkün değildir. Örnekler ise gerçekleşmiş olan olaylardır. Mesela bir doktor hastasına bazı sorular sorar ve aldığı cevaplara göre teşhis ederek ilaç yazar. Sorulan sorular ve verilen cevaplar ile konulan teşhis bir örnek olarak nitelendirilir. Bir doktorun belirli bir zaman içinde hastaları ile yaptığı görüşmeler ve koyduğu teşhisler not edilerek örnek olarak alınırsa yapay sinir ağı benzer hastalıklara benzer teşhisi koyabilir. Elde edilen örneklerin olayı tamamı ile gösterebilmesi çok önemlidir. Ağa olay bütün yönleri ile gösterilemez ve ilgili örnekler sunulmaz ise başarılı sonuçlar elde edilemez. Bu ağın sorunlu olduğundan değil olayın ağa iyi gösterilemediğindedir. O nedenle örneklerin oluşturulması ve toplanması yapay sinir ağı biliminde özel bir öneme sahiptir.
- ✓ **Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir:** Yapay sinir ağlarının eğitilmesi demek, mevcut örneklerin tek tek ağa gösterilmesi ve ağın kendi mekanizmalarını çalıştırarak örnekteki olaylar arasındaki ilişkileri belirlemesidir. Her ağı eğitmek için elde bulunan örnekler iki ayrı sete bölünürler. Birincisi ağı eğitmek için (eğitim seti) diğeri ise ağın performansını sınamak için (test seti) kullanılır. Her ağ önce eğitim seti ile eğitilir. Ağ bütün örneklerle doğru cevaplar vermeye başlayınca eğitim işi tamamlanmış kabul edilir. Daha sonra ağın hiç görmediği test setindeki örnekler ağa gösterilerek ağın verdiği cevaplara bakılır. Eğer ağ hiç görmediği örneklerle kabul edilebilir bir doğrulukta cevap veriyor ise o zaman ağın performansı iyi kabul edilir ve ağ kullanıma alınır. Eğer ağın performansı yetersiz olursa o zaman yeniden eğitmek veya yeni örnekler ile eğitmek gibi bir çözüme gidilir. Bu işlem ağın performansı kabul edilebilir bir düzeye gelinceye kadar devam eder.
- ✓ **Görülmemiş örnekler hakkında bilgi üretebilirler:** Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.
- ✓ **Algılamaya yönelik olaylarda kullanılabilirler:** Ağlar daha çok algılamaya yönelik bilgileri işlemede kullanılırlar. Bu konuda başarılı oldukları yapılan uygulamalarda görülmektedir. Bilgiye dayalı çözümlerde uzman sistemler kullanılmaktadır. Bazı durumlarda yapay sinir ağı ve uzman sistemleri birleştirmek daha başarılı sistemler oluşturmaya neden olmaktadır.
- ✓ **Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler:** Genel olarak ağların çoğunun amacı kendisine örnekler halinde verilen örüntülerin kendisi veya diğerleri ile ilişkilendirilmesidir. Diğer bir amaç ise sınıflandırma yapmaktır. Verilen örneklerin kümelendirilmesi ve belirli sınıflara ayrıştırılarak daha sonra gelen bir örneğin hangi sınıfa gireceğine karar vermesi hedeflenmektedir.
- ✓ **Örüntü tamamlama gerçekleştirebilirler:** Bazı durumlarda ağa eksik bilgileri içeren bir örüntü veya bir şekil verilir. Ağın bu eksik bilgileri bulması istenir.

Örneğin yırtık bir resmin kime ait olduğunu belirlemesi ve tam resmi vermesi gibi bir sorumluluk ağıdan istenebilmektedir. Bu tür olaylarda yapay sinir ağlarının çok etkin çözümler ürettiği bilinmektedir.

- ✓ **Kendi kendini organize etme ve öğrenebilme yetenekleri vardır:** Yapay sinir ağlarının örnekler ile kendisine gösterilen yeni durumlara adapte olması ve sürekli yeni olayları öğrenebilmesi mümkündür.
- ✓ **Eksik bilgi ile çalışabilmektedirler:** Yapay sinir ağları kendileri eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilirler. Eksik bilgiler ile de çalışmaya devam ederler. Hâlbuki geleneksel sistemler bilgi eksik olunca çalışmazlar. Burada bir noktaya dikkatleri çekmekte fayda vardır. Yapay sinir ağlarının eksik bilgiler ile çalışması performanslarının düşeceği anlamına gelmez. Performansın düşmesi eksik olan bilginin önemine bağlıdır. Hangi bilginin önemli olduğunu ağ kendisi eğitim sırasında öğrenmektedir. Kullanıcıların bu konuda bir fikri yoktur. Ağın performansı düşük olunca, kayıp olan bilginin önemli olduğu kararına varılır. Eğer ağın performansı düşmez ise eksik olan bilginin önemli olmadığı anlaşılır.
- ✓ **Hata toleransına sahiptirler:** Yapay sinir ağlarının eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. Ağın bazı hücrelerinin bozulması ve çalışamaz duruma düşmesi halinde ağ çalışmaya devam eder. Ağın bozuk olan hücrelerinin sorumluluklarının önemine göre ağın performansında düşmeler görülebilir. Hangi hücrelerin sorumluluklarının önemli olduğuna da yine ağ eğitim esnasında kendisi karar verir. Bunu kullanıcı bilmemektedir. Ağın bilgisinin yorumlanamamasının sebebi de budur.
- ✓ **Belirsiz, tam olmayan bilgileri işleyebilmektedirler:** Yapay sinir ağlarının belirsiz bilgileri işleyebilme yetenekleri vardır. Olayları öğrendikten sonra belirsizlikler altında ağlar öğrendikleri olaylar ile ilgili ilişkileri kurarak kararlar verebilirler.
- ✓ **Dereceli bozulma gösterirler:** Yapay sinir ağlarının hatalara karşı toleranslı olmaları bozulmalarının da dereceli (göreceli) olmasına neden olmaktadır. Bir ağ (Network) zaman içerisinde yavaş yavaş ve zarif bir şekilde bozulur. Bu eksik olan bilgiden veya hücrelerin bozulmasından kaynaklanır. Ağlar, herhangi bir problem ortaya çıktığında hemen anında bozulmazlar.
- ✓ **Dağınık belleğe sahiptirler:** Yapay sinir ağlarında bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir. Tek bir bağlantının bir anlamı yoktur. Daha önce belirtildiği gibi ağın bilgilerinin açıklanamamasının sebeplerinden birisi de budur. Bu ağlarda, ağın tamamı öğrendiği olayın bütünü karakterize etmektedir. O nedenle bilgiler ağa dağıtılmış durumdadır. Bu ise dağınık bir belleğin doğmasına neden olmaktadır. Sadece nümerik bilgiler ile çalışabilmektedirler: Yapay sinir ağları sadece nümerik bilgiler ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin nümerik gösterime çevrilmeleri gerekmektedir. Burada açıklanan özellikler dikkatlice incelenirse aslında yapay sinir ağlarının bilgisayar bilimine oldukça avantajlı

katkılarının olduğu görülebilir. Geleneksel bilgisayar yazılım teknolojisi ile çözülemeyen birçok problemin yapay sinir ağları ile çözülebileceği görülebilir. Mesela yapay sinir ağları, eksik, normal olmayan, belirsiz bilgileri işleyebilen en güçlü problem çözme tekniğidir denilse yanlış olmaz. Belirsiz bilgileri işlemede bulanık önergeler mantığı (Fuzzy Logic) gibi teknikler olsa bile eksik bilgi ile çalışabilen teknikler bulmak çok zordur.

3.1.2.9. Yapay sinir ağlarının dezavantajları

Yapay sinir ağlarının yukarıda belirtilen birçok avantajlı özelliklerinin yanı sıra bazı dezavantajları da vardır. Yapay sinir ağlarının donanım bağımlı çalışmaları önemli bir sorun olarak görülebilir. Ağların temel varoluş nedenlerinden biriside paralel işlemciler üzerinde çalışabilmeleridir. Ağların özellikle, gerçek zamanlı bilgi işleyebilmeleri paralel çalışabilen işlemcilerin varlığına bağlıdır. Günümüzdeki makinelerin çoğu seri şekilde çalışabilmekte ve aynı zamanda sadece tek bir bilgiyi işleyebilmektedir. Paralel işlemleri seri makinelerde yapmak ise zaman kaybına yol açmaktadır. Bunun yanı sıra bir ağın nasıl oluşturulması gerektiğini belirleyecek kuralların olmaması da başka bir dezavantajdır. Her problem farklı sayıda işlemci gerektirebilir. Bazı problemleri çözebilmek için gerekli olan paralel işlemcilerin tamamını bir arada (paralel olarak) çalıştırmak mümkün olmayabilir.

Probleme uygun ağ yapısının belirlenmesi genellikle deneme yanılma yolu ile yapılmaktadır bu ise önemli bir problemdir. Çünkü eğer problem için uygun bir ağ oluşturulmaz ise çözümü olan bir problemin çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusu olabilir. Bu aynı zamanda bulunan çözümün en iyi çözüm olduğunu da garanti etmez. Yani yapay sinir ağları kabul edilebilir çözümler üretebilir. Optimum çözümü garanti etmez. Bazı ağlarda ağın parametre değerlerinin (mesela öğrenme katsayısı, her katmanda olması gereken proses elemanı (yapay hücrelerin) sayısı, katman sayısı vb.) belirlenmesinde de bir kural olmaması diğer bir problemdir. Bu, iyi çözümler bulmayı zor durumda bırakan bir etken olarak görülebilir. Bu parametrelerin belirlenmesi de kullanıcının tecrübesine bağlıdır. Her problem için ayrı faktörleri dikkate almayı gerektirmektedir. Bu parametre değerleri için belirli standartların oluşturulması çok zor olduğundan her problem için ayrı ayrı değerlendirmeler yapılması gerekmektedir. Bu da önemli bir dezavantaj olarak görülebilir.

Ağın öğreneceği problemin ağa gösterimi de çok önemli bir problemdir. Yapay sinir ağları yukarıda belirtildiği gibi sadece nümerik bilgiler ile çalışmaktadırlar. Problemin nümerik gösterime dönüştürülmesi lazımdır. Bu ise kullanıcının becerisine bağlıdır. Uygun bir gösterim mekanizmasının kurulamamış olması problemin çözümünü engelleyebilir veya düşük performanslı bir öğrenme elde edilebilir. Problemin nümerik gösterimi mümkün olsa bile bunun ağa gösteriliş şekli problemin başarılı bir şekilde çözülmesini yakından etkiler. Örneğin bir olay hem ayrık (binary-ikili) hem de sürekli değerler ile gösterilebilir. Bunun hangisinin daha başarılı bir öğrenme gerçekleştirileceği ise bilinmemektedir. Bu konuda, kullanıcının tecrübesi de yeterli olmayabilir. Bu günümüzde birçok olayın yapay sinir ağları ile çözülememesinin en önemli nedenlerinden birisidir.

3.1.3. Bulanık mantık

“*Bulanık*” kelimesi, “kesin (net) olmayan, karışık, belli belirsiz” şeklinde tanımlanabilir. “*Bulanıklık*” ise net olmama durumudur ve bir belirsizlik çeşididir.

Birçok belirsizlik çeşidinden bahsedebiliriz;

- Numaralı gözlük takanın gözlüğünü çıkardığında gördüğü manzara bulanık bir belirsizlikken, “yüz” tabirini kullanıp hiçbir yan açıklama yapmama çok anlamdan kaynaklanan bir belirsizliği gösterir.
- Yine ‘bir adam’ derken sayıca bir olmakla beraber kim olduğu belli olmayan bir adamdan bahsetmek de belirsizlik ifade eden bir durumdur.
- Renklerin birbirinden ayırt edilmesinde de aynı güçlük vardır. Sarı ile açık sarı veya turuncu arasındaki sınır nereden geçer? Bu sınırın net bir yeri yoktur.

Klasik mantığın birçok alanda yetersiz hale gelmesi, insan zekasının işleyişine uygun olmaması sonucu bulanık mantık kavramı popüler hale gelmiştir. Bulanık mantık, bulanıklığı açıklayan mantıktır. Daha geniş bir ifade ile, bulanık mantık, üyelik derecelerini temel almış, ikili mantığın aksine çok değerli, matematik bir disiplindir. Bulanık mantık, yanlış veya doğru olma durumlarından çok, doğru olma durumunun olasılıklarına dayanır. Ayrıca, bulanık mantık uygulaması, matematik modele ihtiyaç duymamaktadır.

3.1.3.1. Bulanık mantık gelişim süreci

Bulanık mantığın kilit kavramını, mantıkçılar ilk olarak 1920’lerde “her şey derecelendirme sorunudur” kavramı ile ortaya atmışlardır. 20. yüzyılın başında Bernart Russel, modern küme kuramı ve mantığın tam merkezinde eski Yunan paradoksunu bulmasıyla mantık üzerine modern incelemelere başlamıştır (Russell 1901).

Polonyalı mantıkçı Jan Lukasiewicz, 1920’li yıllarda Russel’den bağımsız olarak önermelerin, ikili mantığın 1 ve 0 değerleri arasında kesirli değerleri alabildiği çok değerli mantık ilkelerini ortaya koymuştur (Łukasiewicz 1920). Kuantum felsefecisi Max Black 1937 yılında “Philosophy of Science” dergisinde yayınlanan bir makalesinde elemanlardan oluşan kümelere çok değerli mantık kurallarını uygulayarak ilk bulanık küme eğrilerini çizmiştir (Black 1937). Bu gelişmeden yaklaşık 30 yıl sonra Berkeley Üniversitesinden Lotfi A. Zadeh, bu alana adını veren “Bulanık Kümeler” adlı yazısını yayınlamıştır. Zadeh, bir kümenin tüm elemanlarına Lukasiewicz’in mantığını uygulayarak bulanık kümeler için eksiksiz bir cebir geliştirmiştir. Fakat bulanık mantık, Londra’daki Queen Mary College’de Prof. Dr. Ebrahim H. Mamdani’nin 1974 (Mamdani 1974) yılında bir buhar makinesi için bulanık mantıkla işletilen bir denetleyici tasarlamasına kadar kullanım alanı bulamamıştır.

Bulanık mantık kuramının ilk önemli endüstriyel uygulaması, 1980 yılında Danimarka’daki bir çimento fabrikasında gerçekleştirilmiştir. Değirmen içinde çok hassas bir denge ile oranlanması gereken sıcaklık ve oksijen ayarı en uygun biçimde ayarlanmıştır. 1980 yılında F.H. Smidth Japon Fuji Elektrik firmasında su arıtma sistemlerinin kontrolünde bulanık mantığı kullanmıştır. Daha sonra yine bir Japon

firması olan Hitachi, 1987 yılında otomatik tren bulanık kontrol sistemini geliştirmiştir. Bunlar 1990'lı yılların ilk yarısında Japonya'da yayılacak olan bulanık mantığın ilk öncüleri sayılmıştır.

Bulanık sistemlerin Japonya'daki başarısı sonucunda 1990 yılından itibaren bütün dünyada özellikle mühendislik alanlarında ve endüstride bulanık sistemler hızla kullanılmaya başlanmıştır. Su arıtmadan metro denetimine, elektronik pazarından, otomotiv ürünlerine, ısı, sıvı, gaz akımı denetiminden, kimyasal ve fiziksel süreç denetimlerine kadar bir çok alanda kullanılmıştır.

Bulanık mantığın ilk uygulama alanı İnşaat Mühendisliği ile ilgisi olan çimento sanayi ve su arıtma sistemleri olmuştur. Daha sonra buhar tribünü, nükleer reaktör, asansör ve vinç denetimi gibi farklı alanlarda da bulanık mantıktan yararlanılmıştır. Canon, Mitsubishi, Boeing, General Motors, Allen-Bradley, Chrysler gibi önemli firmalar ürünlerinde bulanık sistemlerden yararlanmaktadır (Şaka 1999).

3.1.3.2. Bulanık mantık kavramı

Bir kümenin elemanları, $(0,1)$ arasında değişen üyelik dereceleri alarak kümeye dahil oluyorsa bu tür kümelere bulanık kümeler denilmektedir (Jacob 2003). 60'lı yıllar boyunca Prof. Dr. Lütü Zadeh, rastgeleliğin farklı bir biçimi olan, kesin olmama hali üzerinde durmuştur. 'Belirsizlik' yani 'kesin olmama' kavramına dayanan bu önermeye "Bulanık Mantık" ismini vermiştir. Bu önermeyle, insan dilinin doğasında bulunan belirsizliğe matematiksel bir yaklaşım getirmiştir.

Klasik mantıkta her şey ikili kodlar üzerine kurulmuştur. Oysa dünyamızda pek çok şey ikili değildir. Yani insanları 'iyi' ve 'kötü' diye iki gruba kesin sınırlarla ayıramayız. İyilik ve kötülük kutuplarının arasında pek çok derece mevcuttur. Yani hayat sadece 'siyah-beyaz' üzerine kurulmamıştır. Doğada gri de vardır ve 'Bulanık' doğadaki gri'nin bilim ve endüstride kullanılmasıdır.

Bulanık mantığın genel özellikleri Zadeh tarafından şu şekilde ifade edilmiştir (Zadeh 1965):

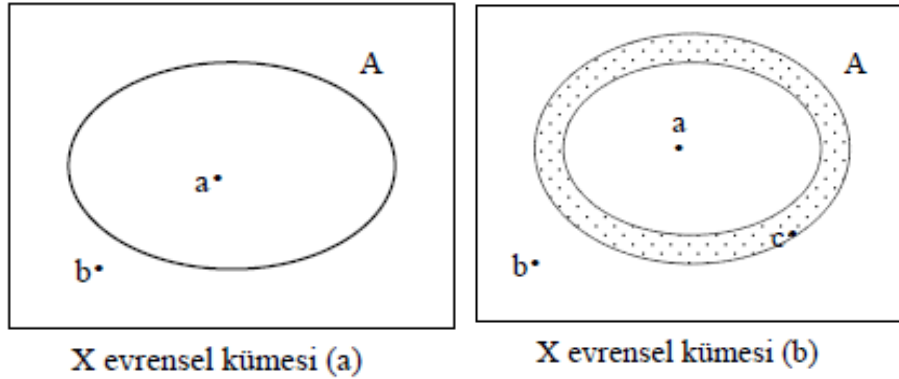
- 1) Bulanık mantıkta kesin değerlere dayanan düşünce yerine yaklaşık düşünce kullanılır.
- 2) Her şey $[0,1]$ aralığında belirli bir derece ile gösterilir.
- 3) Bulanık mantıkta bilgi büyük, küçük, az, çok... gibi dilsel ifadeler şeklindedir.
- 4) Bulanık çıkarım işlemi dilsel ifadeler arasında tanımlanan kurallar ile yapılır.
- 5) Her mantıksal sistem bulanık olarak ifade edilebilir.
- 6) Matematiksel modeli çok zor elde edilen sistemler için de çok uygundur.

Günlük hayatımızda 'kontrol' olarak niteleyebileceğimiz pek çok şey yaparız. Örneğin bisiklete bineriz. Bunu yapabilmemiz için elimizde deney sonuçları ya da bir diferansiyel denklem sistemi yoktur. Bu kontrolü basit kurallarla eğitilip uzmanlık kazanarak sağlarız. Kazanılan uzmanlık sayesinde, herhangi bir çaba içerisine girmeden, hislerimizle hareketimizi kontrol edebiliriz.

İnsanların herhangi bir sistemi kontrol ederkenki düşünce ve sezgilerine bağlı davranışlarını temel alan bulanık mantık kontrol, makinelere insanların özel verileri işleyebilme yeteneğini ve insanların deneyimlerinden ve öngörülerinden yararlanarak çalışma yeteneğini kazandırır. Bu yetenek kazandırılırken sembolik ifadeler kullanılır. Bisiklet örneğiyle devam edecek olursak: Eğer bisiklet sağa doğru yönelmiş ise; o halde tekerlekleri sola çevir. *Eğer-O halde* (if-then) yapısındaki kurallar, bulanık kontrol sisteminin temelini oluşturmaktadır. Kurallarda kullanılan “büyük, küçük, sıcak, kısa vb.” sözel sembolik ifadeler bulanık kümelerle dönüştürülür. Bulanık kümelerin bir araya getirilmesi ve bu kümeler üzerinde yapılan işlemlerle, *eğer - o halde* kuralları matematiksel olarak biçimlendirilir.

3.1.3.3. Bulanık kümeler

Bu kuralların sözel olarak, kelimelerle ifadesi kolaydır. Fakat sözel notasyonlarla ifade edilen ‘Bulanıklık’ın kontrol teorisinde kullanılması için matematiksel bir yol gerekmektedir. Bulanık kavramının matematiksel modeli ilk defa 1965 yılında Zadeh tarafından ‘Bulanık kümeler’ kuramıyla oluşturulmuştur. Zadeh kesin bir üyelik kriteri tanımlamasına sahip olmayan nesnelere matematiksel olarak sınıflandırırken ‘üyelik derecesi’ kavramını kullanmıştır (Zadeh 1965).



Şekil 3.14.a. Kesin kümelerin sınır gösterimi

b. Bulanık kümelerin sınır gösterimi

Şekil 3.14.a. X evrensel kümesinin içerisinde sınırları kesin olarak belli olan bir A kümesini göstermektedir. Açıkça bellidir ki, a A kümesinin elemanıdır, b ise elemanı değildir. O halde a' nın A kümesi içindeki üyeliği 1 ile b' nin üyeliği ise 0 ile gösterilir.

Şekil 3.14.b'deki A kümesi bir bulanık kümedir ve sınırları kesin değildir. Burada a, A kümesinin elemanıdır. b ise A kümesinin elemanı değildir, Ancak c noktası için A kümesinin elemanıdır ya da A kümesinin elemanı değildir diyemiyoruz. Bu durumda A kümesinin elemanı olan a noktasının ağırlığı 1 A kümesinin elemanı olmayan b noktasının ağırlığı 0 ise, A kümesinin elemanı olup olmadığı konusunda kesin bir şey söyleyemediğimiz c noktasının üyelik derecesinin de $[0,1]$ arasında bir değerde olması gerekmektedir.

3.1.3.4. Bulanık kümelerde temel işlemler

Klasik kümeler üzerinde tanımlanan üç temel işlem olan tümleyen alma, birleşim ve kesişim işlemlerinin bulanık kümeler üzerine genişletilmesi işlemi birden fazla yolla yapmak mümkündür. Bulanık kümeler ile, uygulama alanının getirdiği özelliklere göre yeni işlemler tanımlanabilir. U uzayından, A kümesinin elemanlarını oluşturmak için seçtiğimiz x objeleri $[0,1]$ reel aralığında üyelik dereceleri alıyorsa, A kümesi bulanık bir kümedir. $\mu_A(x)$, elemanların A kümesine üyelik derecelerini göstermektedir. Dolayısıyla bulanık kümeler sıralanmış ikililerden oluşur (Elmas 2007).

$$A = \{ (x, \mu_A(x)) \mid x \in U \} \quad (3.8)$$

Bu denklemi Zadeh aşağıdaki şekilde ifade etmiştir.

$$\begin{aligned} A &= \{ \mu_A(x_1) / x_1 + \mu_A(x_2) / x_2 + \dots \} \\ &= \{ \sum (\mu_A(x_i) / x_i) \} \\ &= \{ \int (\mu_A(x) / x) \} \end{aligned} \quad (3.9)$$

❖ Kapsama

A ve B 'nin x 'lerden oluşan bulanık kümeler olduğu varsayılmıştır. B 'nin A 'yı kapsama şartı;

$$\mu_A(x) \leq \mu_B(x) \quad x \in X \quad (3.10)$$

$(A \subset B)$ şeklinde sembolize edilir.

❖ Denklik

A ve B 'nin x 'lerden oluşan bulanık kümeler olduğu varsayılmıştır. A 'nın B 'ye denk olma şartı:

$$\mu_A(x) = \mu_B(x) \quad (3.11)$$

$A = B$ şeklinde sembolize edilir.

❖ Kesişim

A ve B 'nin x 'lerden oluşan bulanık kümeler olduğu varsayılmıştır. A ve B bulanık kümesinin kesişimi $A \cap B$ şeklinde sembolize edilir.

$$\begin{aligned} \mu_{A \cap B} &= \min \{ \mu_A(x), \mu_B(x) \} \quad x \in X \\ &= \mu_A \wedge \mu_B \end{aligned} \quad (3.12)$$

biçiminde tanımlanır. Kesişim "ve" birleştiricisine karşılık gelir.

❖ Birleşim

A ve B' nin x' lerden oluşan bulanık kümeler olduğu varsayılmıştır. A ve B bulanık kümesinin birleşimi AUB şeklinde sembolize edilir. AUB bulanık kümesi, A ve B' yi kapsayan en küçük bulanık küme olarak tanımlanır. AUB kümesi oluşturulurken maksimum işlemcisi (V) dikkate alınır. Birleşim;

$$\begin{aligned}\mu_{AUB} &= \max \{ \mu_A(x), \mu_B(x) \} \quad x \in X \\ &= \mu_A \vee \mu_B\end{aligned}\quad (3.13)$$

biçiminde tanımlanır.

❖ Tümlen

A ve B' nin x' lerden oluşan bulanık kümeler olduğu varsayılmıştır. B' nin A' nın tümlenmesi olması şartı:

$$\mu_{A^c}(x) = 1 - \mu_B(x) \quad x \in X \quad (3.14)$$

olarak ifade edilir. A bulanık kümesinin tümlenmesi A^c , A şeklinde sembolize edilir ve tümlen "değil" bağlacına karşılık gelir.

❖ Cebirsel Toplam

A ve B' nin x'lerden oluşan bulanık kümeler olduğu varsayılmıştır. A ve B'nin cebirsel toplamları:

$$\mu_{A \oplus B}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x) \mu_B(x) \quad x \in X \quad (3.15)$$

olarak ifade edilip, $(A \oplus B)$ şeklinde sembolize edilir.

❖ Cebirsel Çarpım

A ve B' nin x' lerden oluşan bulanık kümeler olduğu varsayılmıştır. A ve B'nin cebirsel çarpımları:

$$\mu_{AB}(x) = \mu_A(x) \cdot \mu_B(x) \quad x \in X \quad (3.16)$$

olarak ifade edilip, AB şeklinde sembolize edilir.

❖ Fark

A ve B' nin x' lerden oluşan bulanık kümeler olduğu varsayılmıştır. A'nın B' den farkı;

$$\mu_{A \ominus B}(x) = \min \{ \mu_A(x), \mu_{B^c}(x) \} \quad x \in X \quad (3.17)$$


$$\mu_{A \ominus B}(x) = \{ \mu_A(x) \wedge \mu_{B^c}(x) \} \quad x \in X \quad (3.18)$$

olarak sembolize edilir ve belirtilir.

3.1.3.5. Üyelik fonksiyonu

Kuralları sisteme girmek için ihtiyaç duyduğumuz üyelik fonksiyonu, her girişin katılımının büyüklüğünün grafik temsilidir. Üyelik fonksiyonu, gerekli her giriş ile ağırlığı birleştirmekte, girişler arasındaki fonksiyonel hataları belirlemektedir ve son olarak bir çıkış cevabı oluşturmaktadır. Kurallar, son çıkış kararının bulanık çıktıdaki etkisini belirlemek için, faktörleri ağırlıklandırarak, giriş üyelik değerlerini kullanmaktadır.

Bir üyelik fonksiyonu, 0 ile 1 arasında bir üyelik değerinde giriş uzayındaki her noktanın nasıl belirleneceğinin ayrıntısıyla planlamasını sağlamaktadır. Bulanık kümenin her elemanı, küme içerisinde bir üyelik değerine sahiptir ve bulanık A kümesinin elemanlarının değerleri Şekil 2.15’de gösterildiği gibi 0 ile 1 arasındaki sayılardan oluşur (Elmas 2003).

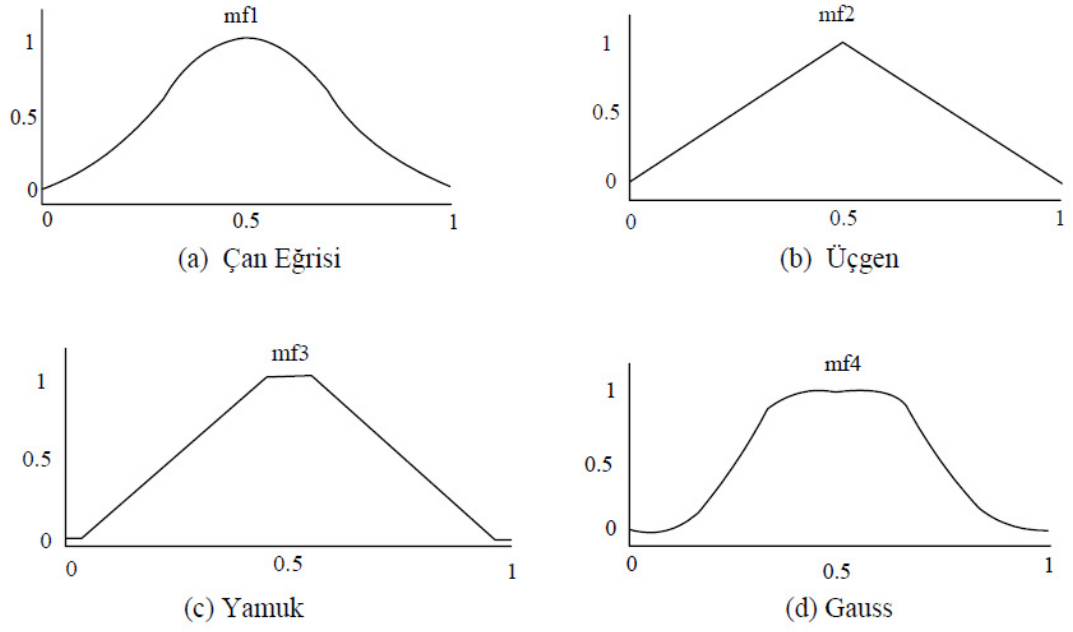


Şekil 3.15. A kümesinin üyelik fonksiyonu



Bir bulanık küme, kendi aitlik fonksiyonu ile açık olarak temsil edilebilmektedir. Şekil 3.15’de görüldüğü gibi, aitlik fonksiyonu 0 ile 1 arasındaki her değeri alabilir. Böyle bir aitlik fonksiyonu ile ‘kesinlikle ait’ (1) veya ‘kesinlikle ait değil’ (0) arasında istenilen incelikte ayarlama yapmak mümkündür (Elmas 2003).

Bir fiziksel değişkenin üyelik derecesini tanımlamak için kullanılan üyelik fonksiyonları, dilsel ifadelerden oluşan bir anlam grubudur. Bulanık küme teorisinin temelini oluşturan üyelik fonksiyonları 0 ile 1 arasında bir üyelik derecesine sahiptir. Üyelik derecesi, elemanın bulanık kümeyle temsil edilen kavrama ne derece uygun olduğu veya bulanık kümenin temsil ettiği özellikleri ne dereceye kadar taşıdığını gösterir. Üyelik fonksiyonu, biçimsel olarak denetlenen sürecin özelliklerine göre değişik şekillerde olabilir. Üyelik fonksiyonları, genellikle aşağıda Şekil 3.16’da görülen, üçgen (triangular), yamuk (trapezoidal), gauss veya çan eğrisi (bell-shaped) biçimlerinde olmaktadır.


En yaygın olarak kullanılan üyelik fonksiyonu üçgen tipidir. Çok daha karmaşık üyelik fonksiyonları kullanılabilir fakat karmaşıklık arttıkça, daha fazla hesaplama gücü gerekmektedir.




Şekil 3.16. Çeşitli üyelik fonksiyonu biçimleri

Dilsel Terim:ABA ∩ B:


$$\text{Min: } \mu_{A \cap B}(x) = \text{Min} \{ \mu_A(x), \mu_B(x) \}$$

A ∪ B:

$$\text{Max: } \mu_{A \cup B}(x) = \text{Max} \{ \mu_A(x), \mu_B(x) \}$$

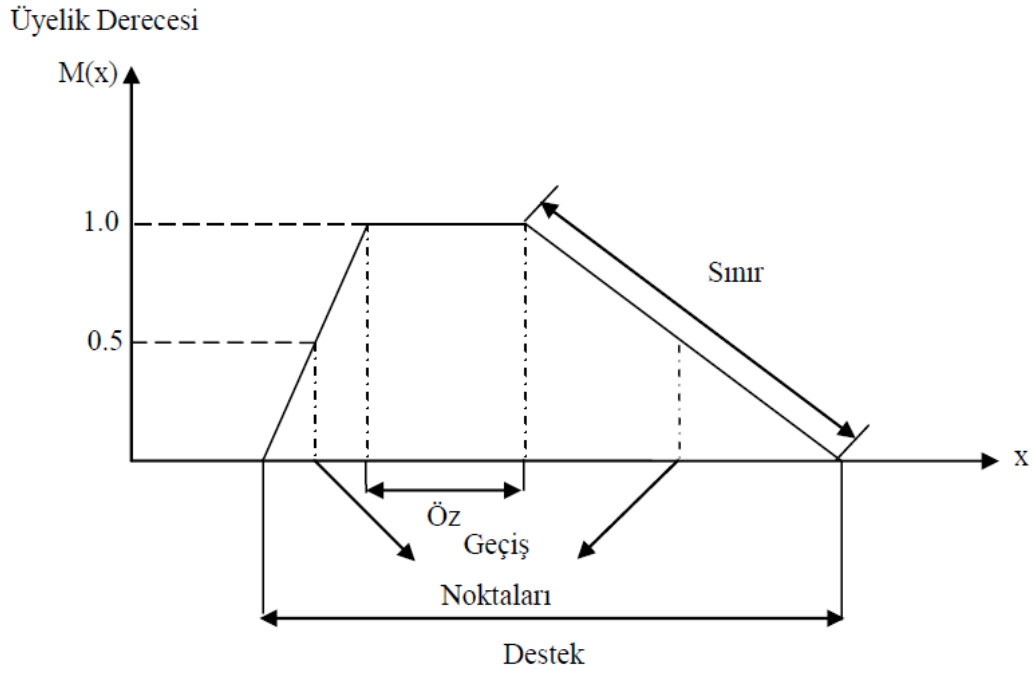
Ā:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x)$$



Şekil 3.17. Küme işlemlerinin üyelik fonksiyonları ile tanımlanması

Bazı Küme işlemlerinin üyelik fonksiyonlarına bağlı olarak nasıl uygulandığı Şekil 3.17'de görülmektedir. Üyelik fonksiyonları genelde uzman görüşü dikkate alınarak öznel olarak oluşturulmaktadır fakat bazı uygulamalarda yetersiz kalabilmektedir. Bu sebepten genellikle üyelik fonksiyonları optimizasyon teknikleri ile belirlenmektedir. Şekil 3.18'de bir üyelik fonksiyonunun temel bileşenleri grafik olarak görülmektedir (Tür 2009).

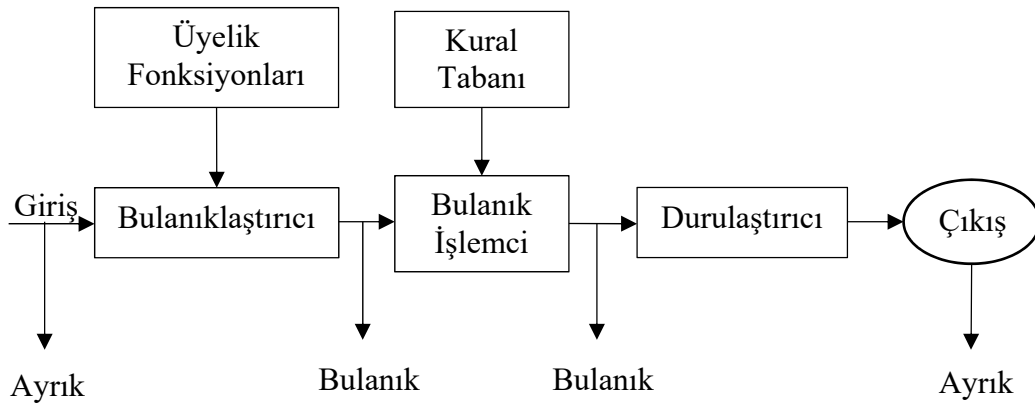


Şekil 3.18. Üyelik fonksiyonunun öz, destek ve geçiş bölgeleri

3.1.3.6. Bulanık çıkarım işlemi

Bulanık mantık kullanan bir sistemde, girişe verilen bilgiye karşılık, kural tabanı kullanılarak bulanık çıkış elde edilmektedir. Bu işlem, sistemin karar verme yetkisine sahip çıkarım birimi tarafından yapılmaktadır. Kurallar ve üyelik fonksiyonları oluşturulan bulanık uzman sistem, bu verileri bütünleştirmek, sistemden bir çıktı elde edebilmek için bulanık çıkarım mekanizmasına ihtiyaç duyar. Çıkarım mekanizması, bilgi tabanının değerlendirilmesi için kurulmuş bir uzman sistem aracıdır. Şekil 3.19'da bulanık modelin tipik yapısı verilmiştir.

Bulanık çıkarım, bulanık mantık kullanarak ayrıntılı olarak verilen bir giriş çıkış haline dönüştüren işlemdir. Başlıca bulanık çıkarım sistemleri, Mamdani, Sugeno ve Tsukamoto tipi bulanık çıkarımlarıdır. Şekil 3.19'da bulanık modelin tipik yapısı görülmektedir (Hines 1997, Clement 1998).




Şekil 3.19. Genel bulanık mantık modeli

❖ Mamdani Bulanık Çıkarım Metodu

Mamdani bulanık modeli ilk kez, uzman insan operatörler tarafından elde edilen dilsel kontrol kuralları bütünü tarafından buhar makinesini ve kazan bileşimini kontrol etmek için İngiliz Prof. Ebrahim Mamdani tarafından önerildi. Şekil 2.20 ve Şekil 2.21, Mamdani türünden iki-kurallı bir bulanık girişim sisteminin çıkış z'nin nasıl x ve y gibi iki keskin girişten elde edilmesini açıklamaktadır.


Şekil 3.20'de açıklanan model iki girişli ve iki kurallı bir bulanık sistemdir. Bulanık çıkarım mekanizması şu biçimde işler: Önce, x ve y girişlerinin her hangi bir andaki değerlerine göre önce kuralın tanımladığı giriş bulanık kümesinde bu girişlerin üyelik dereceleri (her bir kural için ayrı ayrı) belirlenir. Bu iki keskin üyelik derecesi min operatöründen geçirilir. Elde edilen en küçük üyelik derecesi kadar seviyede kırpılmış (kuralın tanımladığı) çıkış bulanık kümesi belirlenir. Bu işlem her bir kural için ayrı ayrı işletildiğinde kural sayısı kadar çıkış bulanık kümeleri elde edilir. Bu çıkış bulanık kümelerde max operatöründen (birleşimi alınır) geçirilir. Sonuç yine bir bulanık kümedir. Keskin değere ulaşmak için sonuç çıkış bulanık kümesi durulandırma işleminden geçirilmelidir (Karakuzu 2006).



Şekil 3.20. Mamdani bulanık girişimli sistemi (T-norm ve S-norm operatörleri sırasıyla min ve max)

Eğer T-norm operatörü olarak cebirsel çarpım ve S-norm operatörü olarak max işlemi seçilirse, bu durumda, bulanık mantığın sonucu her bir kuralın cebirsel çarpım yolu ile belirlenen ateşleme gücü tarafından azaltılan bir bulanık kümeye eşleme yapılması ile belirlenir. Bu durum Şekil 3.21'de gösterilmiştir. Bu tür bir bulanık çıkarım Mamdani'nin

orjinal makalesinde kullanılmamasına rağmen, literatürde sıklıkla kullanılmaktadır. Diğer AND (T-normu) ve OR (S-normu) operatörlerinin farklı varyasyonları ile de Mamdani modeli ile çıkarım yapmak mümkündür (Karakuzu 2006).



Şekil 3.21. Mamdani Bulanık girişimli sistemi (T-norm ve S-norm operatörleri sırasıyla cebirsel çarpım ve max)

❖ Sugeno Bulanık Çıkarım Metodu

Bulanık çıkarım sistemlerinde ilk olarak Mamdani'nin bulanık çıkarım metodu kullanılmıştır. Sugeno bulanık çıkarım metodu ise 1985 yılında verilen giriş ve çıkış kümelerinden bulanık kurallar üretmede sistematik bir yaklaşım geliştirmek için Takagi, Sugeno ve Kang tarafından önerilmiştir. Bulanık çıkarım metodlarının ilk iki kısmı olan girişlerin bulanıklaştırılması ve bulanık operatörlere uygulanması tam olarak bir birinin aynısıdır. Mamdani ile Sugeno arasındaki en önemli fark Sugeno bulanık çıkarım metodunun çıkış üyelik fonksiyonunun doğrusal veya sabit olmasıdır. Sugeno bulanık modelde tipik bir bulanık kural aşağıdaki gibi gösterilmektedir:

$$\text{Eğer } x \text{ } A \text{ ise ve } y \text{ } B \text{ ise } z = f(x, y) \quad (3.19)$$

$z = f(x, y)$ keskin fonksiyon iken A ve B bulanık kümelerdir. $f(x, y)$, x ve y giriş değişkenleri olan bir polinomdur. $f(x, y)$ birinci dereceden Sugeno Bulanık Model olarak isimlendirilir.

Her kurala ait çıkış seviyesi olan z_i , kuralların ağırlık ifadesi olan w_i ile ağırlıklandırılmıştır. Örneğin "AND" kuralı için 1.giriş=x ve 2.giriş=y iken w_i aşağıdaki

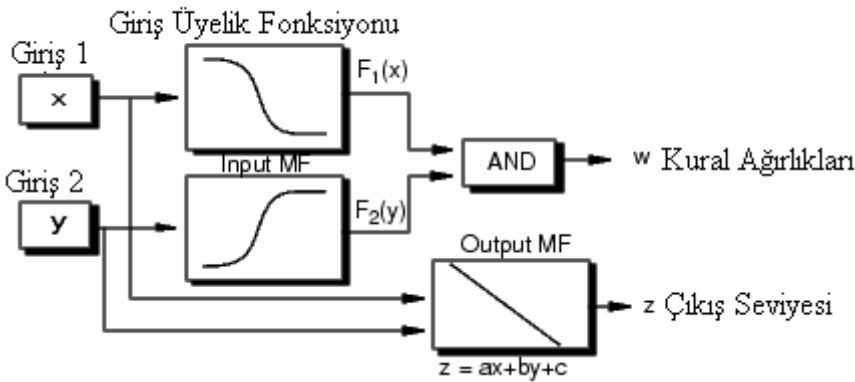
şekilde ifade edilmektedir:

$$w_i = \text{AndMethod}(F_1(x), F_2(y)) \quad (3.20)$$

Burada $F_{1,2}(x,y)$, 1.giriş ve 2.girişe ait üyelik fonksiyonlarını ifade etmektedir. Sistemin en son çıkış ifadesi tüm kuralların çıkışlarının ağırlıklandırılmış ortalamasıdır ve aşağıdaki şekilde ifade edilmektedir:

$$\text{En son çıkış} = \frac{\sum_{i=1}^N w_i z_i}{\sum_{i=1}^N w_i} \quad (3.21)$$

Sugeno, bulanık kuralları Şekil 3.22'deki gibi işlenmektedir.



Şekil 3.22. Sugeno bulanık çıkarım metodu

Mamdani'ye göre daha kapsamlı olması ve işlemsel gücü açısından daha üstün olmasından dolayı Sugeno bulanık çıkarım modeli adaptif tekniklerle birlikte bulanık modellerin çözümünde büyük kullanım alanına sahiptir. Bu adaptif teknikler üyelik fonksiyonlarını amaca göre özelleştirebilmekte böylece bulanık sistemler verileri en iyi şekilde modelleyebilmektedir.

➤ Sugeno Tipi Modelin Avantajları

- ✓ Etkili işlem gücüne sahiptir.
- ✓ Doğrusal tekniklerle çok iyi şekilde çalışmaktadır.
- ✓ Optimizasyon ve adaptif tekniklerle iyi bir şekilde çalışmaktadır.
- ✓ Çıkış yüzeyinde sürekliliğe sahiptir.
- ✓ Matematik analizlerle uyumlu bir şekilde çalışabilmektedir.

3.1.3.7. Durulaştırma yöntemleri

Bulanık genelleme yolu ile elde edilen bulanık alt kümeler, uygulamalarda çoğunlukla durulaştırma ile kesin değerlere dönüştürülürler. Bir bulanık kümenin durulaştırılması işlemi farklı metotlarla yapılabilir (Çizelge 3.3). Çizelge 3.4'te farklı tipte durulaştırma mekanizmalarının matematiksel olarak ifadeleri görülmektedir (Tür 2009).

Çizelge 3.3. Durulaştırma mekanizması tipleri

Durulaştırma Mekanizması Kısaltması	Açıklama
<i>CoG</i>	Ağırlık Merkezi (Centre of gravity)
<i>CoGS</i>	Ağırlık Ortalaması (Centre of gravity for singletons)
<i>CoA</i>	Alan Merkezi (Centre of area)
<i>LM</i>	En Büyük İlk Üyelik (Left most maximum)
<i>RM</i>	En Büyük Son Üyelik (Right most maximum)

Çizelge 3.4. Durulaştırma mekanizmalarının matematiksel olarak ifadeleri

<i>CoG</i>	$U = \frac{\int_{Min}^{Max} u\mu(u)du}{\int_{Min}^{Max} \mu(u)du}$
<i>CoGS</i>	$U = \frac{\sum_{i=1}^p [u_i \mu_i]}{\sum_{i=1}^p \mu_i}$
<i>CoA</i>	$U = u', \int_{u'}^{Max'} \mu(u)du = \int_{u'}^{Max'} \mu(u)du$
<i>LM</i>	$U = \sup(u'), \mu(u') = \sup \mu(u) \Rightarrow u \in [Min, Max]$
<i>RM</i>	$U = \inf(u'), \mu(u') = \sup \mu(u) \Rightarrow u \in [Min, Max]$

3.1.3.8. Bulanık mantığın avantaj ve dezavantajları

Bulanık mantığın avantajlı yönleri;

- ✓ Bulanık mantık insan düşünüş tarzına yakındır.
- ✓ Bir uygulama yapılması esnasında matematiksel bir modele ihtiyaç duymaz.
- ✓ Diğer sistemlere göre yazılımları basit olduğundan, uygulamalar ucuza mal olmakta ve yapılan işler basitleşmektedir.

Bulanık mantığın dezavantajlı yönleri;

- ✗ Bulanık mantık uygulamalarında kullanılan kurallar mutlaka uzman deneyimlerine ve bilgilerine bağlı olarak oluşturulmalıdır.

- ✘ Üyelik fonksiyonları deneme-yanılma yoluyla bulunduğundan çok zaman alabilir.
- ✘ Bulanık mantıkla oluşturulan bir modelin kararlılık analizi yapılmaz, sadece benzeşimi yapılabilir.

Bulanık mantık;

- 1) Geleneksel yöntemlerle yeterli doğrulukta modellenemeyen çok karmaşık sistemlerde,
- 2) Önemli olmayan lineer sistemlerde,
- 3) Başlangıç koşullarında, girişlerinde veya tanımlarında belirsizlikler olan sistemlerde, kullanılması en iyi çözümü vermektedir.

3.1.4. Bulanık sinir ağları (Neuro-Fuzzy)

Yapay sinir ağı ve bulanık mantık tekniklerinin her ikisi de temel olarak insan beyninin çalışma mantığına dayanmaktadır; insan beyninin sonuç çıkarma mekanizmasını taklit ederken, ANN beynin fiziksel yapısı temel alınarak oluşturulmuştur. Her iki teknik de kontrol edilecek sistemin matematik modeline ihtiyaç duymazlar, bu sayede karmaşık ve doğrusal olmayan sistemler ile doğrusal sistemleri modelleyebilirler.

Bulanık sinir ağı, yapay sinir ağları ve bulanık sistemlerin sentezlenmesinden meydana gelen yapay zeka tekniklerinden birisidir. Bulanık mantığın belirsiz bilgileri işleme yeteneğinden ve yapay sinir ağının öğrenme yeteneğinden yararlanabilmek için bu iki teknoloji değişik yöntemlerle birleştirilmektedir.

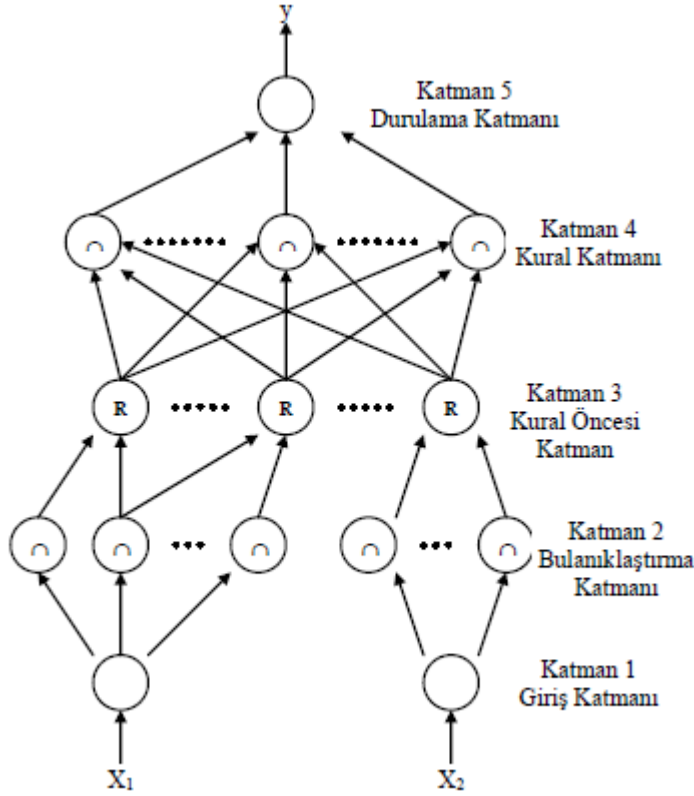
Öğrenme yeteneğine sahip olan sinirsel bulanık sistem sözel kuralları ve üyelik fonksiyonlarını öğrenebilir veya var olanlarını optimize edebilir. Burada üç durum mevcuttur.

- 1) Sistem kural olmaksızın başlar ve problemi çözümlene kadar yeni kural üretimi güncel kural tabanı tarafından tetiklenerek öğrenme sağlanır.
- 2) Sistem, kurallar ile başlar ve bunların performanslarını değerlendirerek kural tabanından yetersiz olanlarını siler.
- 3) Sistem, sabit sayıda kural tabanı ile başlar. Öğrenme sırasında kurallar bir optimizasyon işlemi ile yer değiştirir.

Sıradan sinir ağlarında, düğümler aynı işlevselliktedir. Fakat sinirsel bulanık sistemlerde düğümler farklı işlevselliklere sahiptir. Yani, bazı düğümler girdi değişkenlerinin bazı düğümler çıktı değişkenlerinin sözel terimlerini ifade eder. Sinir ağlarında komşu katmanlardaki düğümler tamamen birbirlerine bağlı iken sinirsel bulanık ağlar da bazı düğümler ve bağlantılar bulanık kuralları temsil etmek için kullanılır.

3.1.4.1. Mamdani bulanık – sinirsel modeli

Şekil 3.23'te önerilen Mamdani yönteminin her katmanının açıklaması aşağıdaki gibidir (Küçük ve Ayvaz 2013):



Şekil 3.23. Mamdani bulanık-sinirsel sistem yapısı

Mamdani bulanık-sinirsel sistem yapısı aşağıdaki gibi açıklanabilir:

Katman 1 (Giriş Katmanı): Bu katmanda hesaplama yoktur. Bu katmandaki her bir düğüm bir giriş değerine karşılık gelmektedir. Bu katmanda giriş değerleri bir sonraki katmana geçirilmektedir. Bu katmandaki bağlantı ağırlık değerleri 1'e sabitlenmiştir.

Katman 2 (bulanıklaştırma) katmanı: Bu katmandaki her bir düğüm katman 1'deki her bir giriş değerinin dilbilimsel ifadesine karşılık gelmektedir. Diğer taraftan çıkış bağlantıları her bir giriş değerinin bulanık kümedeki derecesi olan üyelik değerlerini temsil etmektedir ki bu üyelik değerleri katman 2'de hesaplanır. Kümeleme algoritması her bir giriş değerini bölümlendirecek üyelik fonksiyonunun türüne karar verecektir.

Katman 3 (kural öncesi katman): Bu katmandaki düğüm kurallardan önceki görevi temsil eder. Bu düğümde normalde *T-norm* operatörü kullanılır. Katman 3'deki düğüm çıkışı bulanık kuralların tetikleme derecesini temsil eder.

Katman 4 (kural sonuç katmanı): Bu katmandaki düğümlerin temel iki görevi vardır. Bu da kural öncesi gelenleri birleştirmek ve çıkış ve dilbilimsel etiket için uygun değeri belirlemek. Bu katmandaki düğümün numarası kuralın numarasına eşit olacaktır.

Katman 5 (birleştirme ve durulama katmanı): Bu düğüm *T-conorm* operatörünü kullanarak bütün kuralları birleştirir ve son olarak durulama işleminden sonra yeni çıkış değerini hesaplar.

Mandani neuro-fuzzy sistemler öğreticili öğrenme tekniğini (geri yayılma algoritması) kullanır.

3.1.4.2. ANFIS modeli (Sugeno-Takagi bulanık-sinirsel modeli)

Bulanık mantık ve sinir ağlarının bir arada kullanılmasına en iyi örneklerden biri ANFIS (Adaptive Neural Network Based Fuzzy Inference Systems)'dir. Açılımı "Uyarlamalı Ağ Temelli Bulanık Çıkarım Sistemleri"dir. ANFIS metodu Sugeno-Takagi çıkarım modeli üzerine oturtulmuştur.

Yapay sinir ağı bulanık sistemin parametrelerini belirlemek için kullanılmaktadır. Öğrenme aşamasından sonra bulanık sistem yapay sinir ağına ihtiyaç duymadan çalışmaktadır. Sistem eğitim yaparken yapay sinir ağını, karar verme işleminde de bulanık mantığı kullanmaktadır.

ANFIS, kolay uygulanabilir eğitim algoritmalarını içeren yapısıyla ANN'yi ve uzman bilgi sistemi ile FL'yi bünyesinde barındıran ve son yıllarda birçok alanda yaygın olarak kullanılan bir yapay zekâ tekniği haline gelmiştir. Bir başka deyişle, ANFIS yapısı, Sugeno tipi bulanık sistemlerin, sinirsel öğrenme kabiliyetine sahip bir ağ yapısı olarak tanımlanabilir (Özçalık ve Uygur 2003). Söz konusu ağ yapısı katmanlar halinde yerleştirilmiş ve her biri için ayrı fonksiyonların tanımlandığı düğümlerden oluşmaktadır (Tsoukalas 1996).

Kullanılan matematiğin basit olması, doğrusal olmayan sistemleri modelleyebilme yeteneği, günlük dile dayalı olması, esnek olması (kesin sınırlardan oluşmaması), ve kesin olmayan bilgiye karşı toleranslı olması bulanık mantığa dayalı sistemlerin kullanımının getirdiği en önemli avantajları arasındadır.

ANN ise beynin fizyolojik yapısı temel alınarak tasarlanan sistemler olup birbirleriyle paralel çalışan çok sayıda basit işlemciden oluşurlar. Bir sinir ağıının davranış biçimini büyük oranda nöronlar arasındaki bağlantılar belirler; öğrenilen tüm bilgi bu bağlantılarda saklıdır. ANN belirli bir işlevi yerine getirmek için eğitilebilirler ve bu eğitim bağlantıların değerlerini değiştirmekle sağlanır. ANN'yi geleneksel sistemlerden ayıran en önemli özellikleri öğrenme, genelleme yapabilme ve paralel çalışma özellikleridir. Bu özellikler yapay sinir ağlarına hız, hataya karşı tolerans ve verimlilik gibi avantajlar kazandırmaktadır.

Örnek olarak, x ve y gibi iki girişi olan ve z çıkışına sahip bir bulanık çıkarım mekanizması ele alınacak olunursa, tipik olarak birinci mertebeden Sugeno bulanık modeline ait iki adet "Eğer – O halde (If-Then Rules)" kuralı yazılabilir. Bu kurallar;

Kural 1: Eğer $x \in A_1$ ve $y \in B_1$ ise O halde $z_1 = p_1x + q_1y + r_1$
 Kural 2: Eğer $x \in A_2$ ve $y \in B_2$ ise O halde $z_2 = p_2x + q_2y + r_2$

şeklinde ifade edilebilir.

Burada p_i, q_i ve r_i ($i = 1, 2$) birinci mertebeden Sugeno bulanık modelinin lineer parametreleridir. Şekil 2’de görüldüğü gibi ANFIS yapısı 5 katmana ayrılabilir. Kısaca bu katmanlar açıklanacak olunursa;

Katman 1: Her düğüm için üyelik fonksiyonları yardımı ile bulanık kümeye aitlik derecesini belirten üyelik dereceleri hesaplanır (Eşitlik 3.22).

$$\begin{aligned} R_{1,i} &= \mu_{A_i}(x), \quad i = 1, 2 \\ R_{1,i} &= \mu_{B_{i-2}}(y), \quad i = 1, 2 \end{aligned} \quad (3.22)$$

Burada, x, y ve i düğümündeki deterministik (crisp) girdi değerleri, A_i ve B_i bulanık dilsel terimler ve μ_{A_i} ve μ_{B_i} ise üyelik fonksiyonlarını ifade etmektedir. Literatürde birçok farklı üyelik fonksiyonu tipine rastlanmaktadır.

Genellikle üçgen tip üyelik fonksiyonları basitliklerinden ötürü tercih edilmektedir. Fakat son yıllarda Gauss eğrisi tipindeki üyelik fonksiyonları da yaygın olarak kullanılmaktadır. Örnek olarak çan eğrisi tipi üyelik fonksiyonu aşağıdaki şekilde ifade edilebilir (Eşitlik 3.23).

$$\mu_{A_i} = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (3.23)$$

Burada, $\{a_i, b_i, c_i\}$ “Eğer – O halde” bulanık kural yapısının önerme kısmına bağlı olarak üyelik fonksiyonlarının eğriliklerini değiştiren parametrelerdir.

Katman 2: Birbirlerini izleyen kuralların gerçekleşme derecelerinin “ve” mantıksal işlemi ile çarpımlarının gerçekleştirildiği katmandır. Eşitlik 3.24’te çarpım işlemi matematiksel olarak ifade edilmektedir.

$$\begin{aligned} R_{2,k} &= w_k = \mu_{A_i}(x) \times \mu_{B_j}(y), \quad k = 1, \dots, 4; \\ i &= 1, 2; j = 1, 2 \end{aligned} \quad (3.24)$$

Katman 3: 3.katmandaki i . düğüm, i . kuralın gerçekleşme derecesinin, tüm kuralların gerçekleşme derecelerine oranının hesaplandığı katmandır (Eşitlik 3.25).

$$R_{3,i} = \overline{w}_i = \frac{w_i}{\sum_{k=1}^4 w_k} \quad i = 1, \dots, 4 \quad (3.25)$$

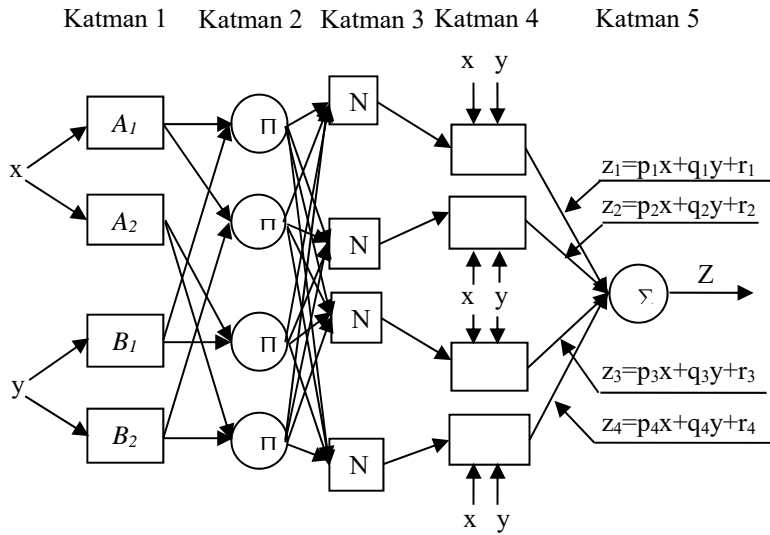
Katman 4: Her i . kuralın toplam çıktı içerisindeki katkısını hesaplandığı katmandır (Eşitlik 3.26).

$$R_{4,i} = \overline{w}_i f_i = \overline{w}_i (p_i x + q_i y + r_i), \quad i = 1, \dots, 4 \quad (3.26)$$

\overline{w}_i , bir önceki katmanın i . düğümünün çıktı değeridir.

Katman 5: Toplam çıkışı hesaplamak üzere kendisine gelen tüm sinyallerin toplandığı düğüm noktasıdır. Bu katmanda bulanık kurallar durulaştırılarak tek bir sayı üretilmektedir (Eşitlik 3.27).

$$R_{5,i} = \sum_{i=1}^4 \overline{w}_i f_i = \frac{\sum_{i=1}^4 w_i f_i}{\sum_{i=1}^4 w_i} \quad (3.27)$$



Şekil 3.24. İki girişli ve dört kurallı bulanık Sugeno modelinin ANFIS yapısı

Şekil 3.24'te iki girişli ve dört kurallı bulanık Sugeno modelinin ANFIS yapısı verilmiştir. Giriş ve çıkış eğitim çiftleri verilen bir fonksiyonu, yapay sinir ağı öğrenebilmektedir. Öğrenme işlemi, ağı içerisindeki ağırlıkların belirlenmesiyle gerçekleşmekte ve verilen fonksiyona optimal yaklaşım sağlanmaktadır. Böylece yapay sinir ağı sistemi öğrenmektedir (Tür ve Balas 2010).

Bulanık mantığın belirsiz bilgileri işleme ve yapay sinir ağının öğrenme yeteneği sistem modelleme de kullanılmıştır. Aynı zamanda bulanık mantık ve yapay sinir ağının birleştirilmesi, birbirlerinin dezavantajlarını da örtmektedir. Sistem modellemeye, hem bulanık mantık hem de yapay sinir ağı açısından ayrı ayrı bakıldığında, modelleme aşamaları Çizelge 3.5'teki gibidir.

Çizelge 3.5. Bulanık mantık ve ANN açısından sistem modelleme adımları

Adım	Bulanık Mantık açısından	Yapay Sinir Ağı açısından
1	Giriş değişkenlerinin belirlenmesi	Giriş değişkenlerinin belirlenmesi
2	Gerekli olan üyelik fonksiyonu ve kural sayısının belirlenmesi	Ağ yapısının ve başlangıç ağırlıklarının belirlenmesi
3	Üyelik fonksiyonlarının ayarlanması	Ağın eğitilmesi
4	Gereksiz kuralların belirlenmesi	Gereksiz hücrelerin iptal edilmesi

3.2. Dalga İklimi ve Dalga İstatistiği

3.2.1. Giriş

Kıyı alanları bakımından zengin sayılabilecek coğrafyamızda dünya ile yarış içerisinde olabilmek için gerek ekonomik gerekse de çevresel etkenler açısından kıyı yapılarına önem gösterilmelidir. Bu yapıların tasarımında dalga parametreleri şüphesiz büyük öneme sahiptir. Kıyı alanlarının çok değişik amaçlar için geniş ölçüde kullanıma açılması oluşan problemlerin farklı yöntemlerle çözümünü gerektirmektedir. Alınması gereken önlemleri kısaca inceleyecek olursak; kıyı çizgisinin korunması, kıyı arkası korunması, kıyı yapıları oluşturulması başlıcalarıdır. Kıyı Mühendisliği Problemlerini incelediğimizde büyük çoğunluğunun dalga ile ilişkisini açıkça görürüz. Çalışmada incelenen dalgalar rüzgar etkenli dalgalardır.

Dünya yüzeyindeki deniz ve göl kıyılarının çok değişik amaçlar için geniş ölçüde kullanıma açılması, bunun yanı sıra gelişen toplumların yarattığı çevre kirliliği sorunları kıyı mühendisliğini birçok değişik probleme karşı aynı ölçüde farklı çözümler üretmek zorunda bırakmıştır. Bunun sonucu olarak kıyı mühendisliğinde kullanılan yapıların hem çeşitleri hem de boyutlandırma kriterlerinde değişiklikler meydana gelmiştir (Kabdaşlı 1992).

Kıyı alanlarının çok değişik amaçlar için geniş ölçüde kullanıma açılması oluşan problemlerin farklı yöntemlerle çözümünü gerektirmektedir. Alınması gereken önlemleri kısaca inceleyecek olursak;

- Kıyı çizgisinin korunması;

Mevcut kıyı çizgisinde oluşan değişimlerin önlenmesi veya yeni bir kıyı çizgisi oluşturulması amacıyla yapılan çalışmalardır.

- ✓ Kıyı duvarları
- ✓ Bitişik dalgakıranlar
- ✓ Bölme perdeleri
- ✓ Kaplamalar
- ✓ Mahmuzlar

- Kum aktarma yapıları kıyı arkası korunması;

Kıyı arkasındaki alanın kullanılması amacıyla bu bölgenin deniz etkilerine karşı korunması için yapılan çalışmalardır.

- ✓ Kıyı duvarları
- ✓ Koruyucu kumsallar
- ✓ Kum tepeleri
- ✓ Kaplamalar

- Bölme perdeleri liman oluşturulması;

Çeşitli amaçlarla gemilerin ve küçük teknelerin dalga ve akıntı etkilerine karşı korunabildikleri bölgelerin oluşturulması için yapılan çalışmalardır.

- ✓ Dalgakıranlar
- ✓ Jetler

Kıyı problemleri çözülürken; çevresel etkilerin ve ekonominin düşünülmesinin yanında, hidrolik açıdan dalga, akıntı ve rüzgar verileri ile araştırmalar yapılmalıdır.

3.2.2. Dalga iklimi ve istatistiği

Dalgalar enerjilerini okyanus veya denizler üzerinde esen rüzgarlardan sağlarlar. Her ne kadar bugüne kadar yapılmış model çalışmalarından elde edilen sonuçların pratik için tam bir sonuç getirmemesine rağmen rüzgar dalgalarının sürtünme etkisiyle meydana geldiği bilinmektedir. Dalgalar hava akımından doğan türbülansın meydana getirdiği basınç kuvvetinin etkisiyle sakin su yüzeyinden oluşmaya başlarlar ve gittikçe gelişirler. Dalgaların bu gelişmesi için gerekli enerji direkt olarak rüzgardan sağlanır.

Rüzgar tarafından üretilen dalgaların boylarının ve frekanslarının oldukça geniş bir değişim aralığı vardır. Çok uzun dalgaların yayılma hızları rüzgar hızlarına eşittir. Çok dik dalgalar ise derin sudaki kırılma şartlarına göre belirlenir. Oldukça karmaşık yapıya sahip, rüzgar etkisiyle oluşan dalgaların 'dalga üretim bölgesinde' çok farklı boya, yüksekliğe ve periyoda sahip oldukları bilinir ve genellikle kısa dalga tipindedirler. Dalga üretim bölgesinden çıkarırken yani ölü denize yaklaştıkça birbirlerini yutarlar. Böylece nispeten sabit karakteristikli dalga grupları meydana gelir (Yüksel vd. 1998).

Rüzgar dalgalarının en karakteristik özellikleri düzensiz yani küçük genlikli dalga teorisinde kabul edildiği gibi sinüzoidal formda olmayışlarıdır. Bu dalgalar;

- ✓ Dik tepeli, yayvan çukurlu asimetrik yapıya sahiptirler.
- ✓ Düzensizdirler, her bir tekil dalga için periyot ve yükseklik bir diğerinden farklıdır.
- ✓ Deniz yüzeyi sürekli değişim içindedir. Dalga yayılma hızı derin suda dalga yüksekliğine ve periyoduna bağlı olduğundan değişik dalga katarları aynı veya farklı fazlarda yayılmaktadırlar.

Bu nedenlerden dolayı rüzgar dalgaları stokastik işlemlerle ifade edilmeye çalışılırlar. Rüzgar dalgalarının yükseklikleri ve periyotları rüzgar hızı (U), feç mesafesi (F , rüzgarların etki mesafesi) ve rüzgar esme süresine (T_w) bağlıdır. Soluğan (ölü) deniz rüzgar etkisinin olmadığı zamanda yayılan dalga olup, bu tip dalgalar genellikle kıyı boyunca mevcuttur. Diğer taraftan da kıyıda patlayan bir fırtına yine bu kıyı boyunca önemli bir dalga üretmeyebilecektir.

Rüzgar su yüzeyinde bir kere stabiliteyi bozduğunda yani çok küçük dalgacıklar meydana getirdiğinde yüzeyin pürüzlülüğü artacaktır. Bunun için gerekli olan minimum teorik rüzgar hızı 6.5 m/s civarındadır. Rüzgarın artan etkisiyle, dalgalara geçen enerji miktarı da artmakta ve böylece dalgalar feç boyunca büyüyerek yayılmaktadırlar.

Dalgaların genliklerinin gittikçe artması öncelikle lineer olmayan bir form almakta ve sonra kırılmaktadırlar. Bu durumda deniz yüzeyinde köpüklenmeler gözlenmektedir (white caps veya white horses). O halde rüzgar dalgaları, dalga üreme bölgesinde meydana gelen dalgacıkların feç boyunca ilerlemeleriyle ağırlık dalgalarına dönüşerek ‘tam gelişmiş deniz’ durumunu oluştururlar.

Rüzgarın dalgaları meydana getirdiği denizin üzerindeki yüzey alanına “feç” denir. Feç; rüzgar hızı ve doğrultusunun yeterince sabit kaldığı bölge olarak bilinir. Rüzgar hızındaki değişim $\pm 2.5 \text{ m/s}$ 'yi, doğrultudaki değişim ise 15° 'yi geçmemelidir. Doğrultuda maksimum 45° 'lik sapma aşıldığında sonuçlar doğru olarak elde edilemez. Feç uzunluğu, üretilen dalgaların karakteristiklerini kontrol eden önemli bir faktördür. Kısa feçler için, dalgalar tam gelişmiş haldeki boyutlarına ulaşmaya fırsat bulamadan üreme alanı dışına yayılmakta ve böylece beklenenden daha küçük yüksekliklere sahip olmaktadır. Dalgaların yükseklikleri ve periyotları feçin başlamasıyla mesafe büyüdükçe artmaktadır. Dalgalar bu durumda feçin sonunda maksimum yüksekliklerine ulaşmaktadırlar. Kısa feçlerde etkin olan dalgalar rölatif olarak küçük yükseklikli ve periyotludurlar. Ancak bunların içinde kısa dalgalar da mevcuttur. Rüzgarın esme süresi dalgaların gelişmesini kontrol eden önemli bir faktördür. Aynı feç uzunluğu ve rüzgar hızı için üretilen dalgaların yükseklikleri sürenin artmasıyla artmaktadır.

Rüzgar hızı, feç uzunluğu ve esme süresi arttıkça rüzgarın ürettiği dalgaların ortalama yükseklikleri artmakta ancak bu belirli limitler içinde olmaktadır. Verilen rüzgar hızı, sınırsız feç ve esme süresi için gelişecek olan dalgaların ortalama yüksekliği ve periyodu sabit bir limit değere sahiptir. Bu limit şartında rüzgardan dalgalara geçen enerji miktarı, dalgaların kırılma ve türbülansı nedeniyle harcadıkları enerji miktarı ile dengede olmaktadır. Dalgaların bu denge durumu ‘Tam Gelişmiş Deniz Durumu (FAS= Fully Arisen Sea)’ olarak bilinir. Bu durum şu şekilde de açıklanabilir; rüzgardan dalgaya olan enerji aktarımı ancak rüzgarın su yüzeyi üzerindeki bileşeni, dalga yayılma doğrultusundaki hızına eşit veya daha büyük bir hıza sahip olması durumunda meydana gelir. Ancak verilen bir U rüzgar hızıyla üretilen dalgaların sahip olabilecekleri sadece bir maksimum dalga yayılma hızı ve periyodu vardır. Bu durumda dalgalar rüzgar ile denge konumuna ulaşırlar, işte bu hal “Tam Gelişmiş Deniz (FAS)” olarak bilinir. Bu durumda dalga spektrumunda artık bir değişim meydana gelmez. Bu hale ulaşabilmek için feç ve rüzgar esme süresinin yeterince uzun olması gerekmektedir. FAS’ın meydana gelmesi için bir minimum rüzgar esme süresi de vardır, eğer rüzgar esme süresi bu minimumdan büyük ise dalga ‘feç limitli’dir, buna karşın rüzgar esme süresi bu minimumdan daha küçük ise FAS meydana gelmez ve bu durumda dalga ‘süre limitli’ olmaktadır (Topaloğlu 2007).

Verilen bir rüzgar hızında (U , m/s) denizdeki denge halinin ulaşması için gerekli minimum feç uzunluğu (F_{FAS} , km) aşağıdaki ifade ile verilmiştir.

$$F_{FAS} = 16 \times U^{3/2} \quad (3.28)$$

Benzer şekilde verilen bir rüzgar hızında denizdeki denge halinin oluşması için gerekli minimum esme süresi (t_{FAS} =saat)

$$t_{FAS} = 11.1 \times U^{1/2} \quad (3.29)$$

ile verilmiştir.

O halde gerçek yani ölçülen veya verilen feç uzunluğu, veya gerçek esme süresi FAS değerlerinden daha küçükse bu durumda dalgalar beklenen maksimum dalga yüksekliğine ulaşmayacaklardır. Bu gibi deniz durumu ‘Gelişmekte Olan Deniz Durumu (Developing Sea) olarak bilinmektedir. Özetlenirse, tam gelişmiş ve gelişmekte olan deniz şartları aşağıdaki ifade edilebilmektedir;

$$\begin{array}{ll} F_{\text{gerçek}} > F_{\text{FAS}} \text{ ve } t_{\text{gerçek}}(T_w) > t_{\text{FAS}} & \text{Tam Gelişmiş Deniz Durumu'nu,} \\ F_{\text{gerçek}} < F_{\text{FAS}} \text{ ve } t_{\text{gerçek}}(T_w) < t_{\text{FAS}} & \text{Gelişmekte Olan Deniz Durumu'nu verir.} \end{array}$$

Su derinliği de, üreyen dalgaların yükseklikleri üzerinde etkilidir. Su derinliği azaldıkça, diğer faktörlerin sabit kalması halinde, dalga yüksekliği azalmaktadır. Ancak dalgalar genellikle denizin derin su bölgesinde üretilirler. Sığ su şartlarında derin su hali için verilen ifadeler kullanılamaz.

Feç uzunluğu genellikle körfezler, göller ve kapalı denizlerde limit hali oluşturur, buna karşın açık denizlerde ise feç uzunluğunun ekseriyetle dalgaların üremesi üzerinde etkisi yeterince yoktur. Feç uzunluklarının belirlenebilmesi için literatürde değişik yöntemler tanımlanmıştır, bunlardan en çok kullanılanı efektif feç uzunluğudur. Kıyılarda göz önüne alınan mevki dikkate alınan dalga yönünden itibaren her iki tarafta $\pm 45^\circ$ lik bir bantta 7.5° lik aralıklarda feç uzunlukları ölçülür ve bu yön için efektif feç olarak tanımlanan feç uzunluğu belirlenmiş olur. Bu aşağıdaki ifade yardımı ile elde edilir.

$$F = \frac{\sum F_i \cos^2 \alpha_i}{\sum \cos \alpha_i} \quad (3.30)$$

Meteorolojik haritalarda da verildiği gibi rüzgar ile izobar (eş basınç) çizgileri aralıkları arasında kesin bir ilişki söz konusudur. Meteorolojik uygulamalarda, izobarlar genellikle 3 mbar veya 4 mbar’lık aralıklara sahiptir (örneğin ABD’de bu 3 mbar’dır). Rüzgar esme yönleri izobar çizgilerine paraleldir ancak su yüzeyindeki sürtünme etkisiyle değişime uğrarlar. İzobarlara normal olan basınç dağılımları dünyanın dönmesinden dolayı oluşan Coriolis kuvvetiyle ve hareketli hava kütlelerinin eğriliğinden dolayı oluşan merkezci kuvvet ile belirlenirler. İzobarlar doğrusal ve paralel olduğundan sadece Coriolis kuvveti önemli olur ve bu durumda meydana gelen rüzgarlar geostrophik rüzgar olarak isimlendirilir. Herhangi bir noktada geostrophik rüzgarın hareket denklemi

$$\frac{\partial p}{\partial n} = 2U\Omega \sin \lambda \quad (3.31)$$

dir. Burada $\partial p / \partial n$ izobara normal olan basıncı, U rüzgar hızını, Ω dünya dönüşünün açısal hızını ve λ enlemleri göstermektedir. Yukarıdaki ifade de $2\Omega \sin \lambda = f$ Coriolis katsayısı olarak bilinir.

Hareketli hava partiküllerinin yörüngeleri eğrisel ise denge halindeki rüzgar hızı yani merkezci kuvvet ve Coriolis kuvvetinin birlikte neden olduğu rüzgar 'gradyan rüzgarı' olarak bilinir.

Feç mesafelerini (F) bulmak için fırtına, yer, süre ve şiddetini gösteren sinoptik haritalardan da faydalanılır. Feç mesafesinin yaklaşık olarak belirlenebilmesi için aşağı yukarı 15°'lik sapma ile izobara teğet olarak rüzgarın başladığı noktadan izobarın eğriliği boyunca ölçülerek bulunur. Eğer rüzgar açıktaki bir kıyıda başlamış ise o zaman feç mesafesi bu kıyı ile sınırlanarak ölçülmek suretiyle belirlenir. Rüzgar esme süresi ve hızları meteorolojik verilerden faydalanılarak bulunur (Topaloğlu 2007).

3.2.3. Verilen bir konumda dalga şartları

Ekstrem dalga şartları; Yani en büyük dalgaların meydana geliş şiddet ve frekanslarının belirlenmesidir. Bu bilgi kıyı yapılarının boyutlandırılması açısından önemlidir.

Dalga iklimi; yani farklı doğrultulardan değişik yükseklik ve periyotlu dalgaların meydana gelme frekanslarının belirlenmesidir. Bu bilgi ise kıyı stabilitesi, erozyonu ve kumlanması ile limanların kumlanması açısından önemlidir.

Ekstrem dalga şartları su kaynakları mühendisliğinde olduğu gibi dolusavak tasarımı için gerekli olan taşkın debilerinin belirlenmesi benzer şekilde bulunur. Dalga iklim verileri de akarsulardaki morfolojik hesaplama için gerekli olan günlük akış verilerine benzemektedir. Hidrolojide yapılan hesaplamalar benzer şekilde, verilen bir konumdaki dalga şartlarının elde edilmesi için iki yöntem vardır; dalga kayıt cihazlarını kullanarak doğrudan ölçme, bu işlem akım ölçüm cihazları ile aynı analojiye sahiptir. Meteorolojik verilerden dolayı tahmin, yani dalga tahminlerinin rüzgar verileri kullanılarak yapılmasıdır. Bu işlem ise yağış ile akış arasındaki ilişkiye benzer bir analojiye sahiptir.

Dalga kayıtlarının analizi için iki yöntem vardır. Bunlar;

- ✓ Her bir dalga kaydının karakteristik dalga yüksekliği ve dalga periyodu parametreleri ile tanımlanmaya çalışılması, bu bir kısa dönem dalga istatistiğidir.
- ✓ Belirli bir dönem boyunca karakteristik dalga yüksekliği ve dalga periyodu parametrelerinin meydana gelme frekansının belirlenmesi, bu ise bir uzun dönem dalga istatistiğidir.

Rüzgar feç boyunca dalgayı oluştururken eğer yeterli süre esmişse ve feç yeterli uzunlukta ise bu durumda tam gelişmiş deniz koşullarının meydana geldiği belirtilmiştir. Başka bir deyişle bu koşullar altında dalgalar erişebilecekleri en büyük dalga yüksekliğine ulaşmaktadır. Bu durumdan sonra rüzgar esmeye devam etse bile artık dalga özellikleri değişmez. Buna karşılık feçin uzunluğu sınırlı ise veya rüzgar esme süresi kısa ise gelişmekte olan deniz durumu söz konusudur. Gelişmekte olan deniz durumunda, olayı feç uzunluğu sınırlıyorsa feç limitli, süre sınırlıyorsa süre limitli durum meydana gelmektedir.

Gelişmekte olan deniz durumu için ve tam gelişmiş deniz durumu için dalga yüksekliği, periyodu ve esme süresi tabloda gösterilen ifadelerle verilmiştir

Çizelge 3.6. Gelişmekte olan deniz durumu ve tam gelişmiş deniz durumu için belirgin dalga yüksekliği, dalga periyodu ve esme süresi (Topaloğlu 2007)

a. Gelişmekte Olan Deniz Durumu

$gH_s/U_A^2 = 1.6 \times 10^{-3} (gF/U_A^2)^{1/2}$	$H_s = 5.112 \times 10^{-1} (U_A F)^{1/2}$	$H_s = 1.616 \times 10^{-2} U_A F^{1/2}$
$gT_m/U_A = 2.857 \times 10^{-1} (gF/U_A^2)^{1/3}$	$T_m = 6.238 \times 10^{-2} (U_A F)^{1/3}$	$T_m = 6.238 \times 10^{-1} (U_A F)^{1/3}$
$gt/U_A = 6.88 \times 10^{-1} (gF/U_A^2)^{2/3}$	$t = 3.215 \times 10^{-1} (F^2/U_A)^{1/3}$	$t = 8.93 \times 10^{-1} (F^2/U_A)^{1/3}$

b. Tam Gelişmiş Deniz Durumu

$gH_s/U_A^2 = 2.433 \times 10^{-1}$	$H_s = 2.482 \times 10^{-2} U_A^2$	$H_s = 2.482 \times 10^{-2} U_A^2$
$gT_m/U_A = 8.134$	$T_m = 8.30 \times 10^{-1} U_A$	$T_m = 8.30 \times 10^{-1} U_A$
$gt/U_A = 7.15 \times 10^4$	$t = 7.296 \times 10^3 U_A$	$t = 2.027 U_A$


3.2.4. Belirgin dalga yüksekliği ve diğer dalga parametreleri

Açık deniz dalga parametrelerinin en çok kullanılanı belirgin dalga yüksekliğidir. Belirgin dalga yüksekliği H_s (veya $H_{1/3}$) olarak yazılır ve belli bir dalga kaydının üçte-birine karşı gelen en büyük dalgaların ortalamasıdır (Chakrabarti 1987).

Deniz kaptanları görsel gözlemlere dayanarak belirgin dalga yüksekliğine yakın dalga yüksekliği değerleri bulmuşlardır. Hoffman ve Walden (1977) Kuzey Atlantik Okyanusunda, India ve Papa meteoroloji istasyonlarındaki okyanus meteoroloji gemilerinde uzman gözlemcilerin dalga yüksekliği gözlemleri ile belirgin dalga yüksekliği arasında bir ilişki olduğunu belirlemişlerdir ve aşağıdaki doğrusal denklemi önermişlerdir.

$$H_s = 0.775 \cdot H_v + 7.0 \quad (3.32)$$

Bu ilişki belirgin dalga yüksekliklerinin yaklaşık 12.2 m 'nin üzerindeki değerleri için geçerlidir. Belirgin dalga yüksekliğinin çıkarılmasına yardım edecek oldukça değerli çok sayıda gözlenmiş ölçümler mevcuttur. (Hogben ve Lumb 1967)



Şekil 3.25. 18 Şubat 1974'te OWS Hava Raportörlüğü'nün J istasyonunda kayıt edilen dalga profili (Chakrabarti 1987)

Belirgin dalga yüksekliği kavramı, belirli bir deniz ortamında bütün dalgaların en büyük üçte birinin ortalama dalga yüksekliği olarak ilk defa Sverdrup ve Munk (1947) 'de ifade edilmiştir. Belirgin dalga yüksekliğinin aşağıdaki tanımında dalga kaydından en büyük üçte-bir dalgalar seçilmiştir. Bu dalga yüksekliklerinin ortalaması belirgin dalga yüksekliğini verir.

$$H_{1/3} = \frac{1}{N} \sum_{i=1}^{N/3} H_i \quad (3.33)$$

burada N, H_i büyükten küçüğe sıralanmış bir dalga kaydında ardışık dalga yüksekliklerinin sayısıdır.

Bu çalışmada $H_{1/3}$, $H_{1/10}$, H_{ort} , H_{max} parametreleri için modelleme ve tahmin yapılmıştır. $H_{1/10}$, dalga kaydındaki en büyük dalgaların onda birinin ortalamasıdır. H_{ort} , dalga kaydındaki ortalama dalga yüksekliğidir. H_{max} ise kayıttaki maksimum dalga yüksekliğidir.

4. METOT

4.1. Filyos Bölgesi

Zonguldak İli, Çaycuma İlçesi, Filyos (Hisarönü) Beldesi, Karadeniz kıyılarının Batı bölümünde, Zonguldak merkeze bağlı Türkali Köyü ile Çaycuma İlçesine bağlı Saz Köyü yakınından denize dökülen Filyos Çayı vadisine kurulmuştur. Çalışma kapsamında, Karadeniz sahilinde yer alan $32^{\circ} 01' 00''$ E enlemi, $41^{\circ} 32' 50''$ N boylamı koordinatlarında bulunan Filyos deniz yöresi incelenmiştir (Şekil 4.1).



Şekil 4.1. Filyos deniz yöresi

Batı Karadeniz kıyısında Zonguldak İli, Çaycuma İlçesi, Filyos beldesi, Bithynia Bölgesini, Paphla-gonia Bölgesinden ayırdığı belirtilen ve kentin hemen doğusunda denize dökülen Billios Irmağı'nın (bugünkü Filyos Çayı) hemen ağzında kurulmuştur. "TİOS" Antik Kenti olarak da bilinmektedir.

Kent, M.Ö. 7. Yüzyılın ikinci yarısında Tios adında bir rahip tarafından bir Miletos Kolonisi olarak kurulmuştur. Geçmişten günümüze kadar ulaşan belgelere göre kent bazen Bithynia, bazen Paphlagonia ve bazen de Pontos kenti olarak nitelenmektedir. Kentin antik çağlarda adı Tios, Tieion, Teion ve Tion olmak üzere değişik adlarla anılmıştır. Kent Helenistik dönem boyunca çeşitli bölge krallıklarının hâkimiyeti altında kalmıştır. Kent üzerindeki Roma hâkimiyeti ise M.Ö. 70 yılında başlamıştır. Yazıtlardan ve sikkelerden Roma İmparatorluğu döneminde imparatorların ve valilerin kentin kalkınmasına önem verdikleri anlaşılmaktadır. Kent Bizans döneminde ise piskoposluk merkezi haline getirilmiştir. Bu, o deneme ait kurşun mühürlerin üzerindeki Tioslu piskoposların adlarından anlaşılmaktadır.


Kentten bahseden Skylaks (M.Ö. V. Yüzyıl) ve sonrasında Stabon (M.Ö. 69 M.S. 14) kentin adının "Teeion" olduğunu belirtirler. Tios adını kullanan Roma dönemi yazarlarından Aelianus (M.S. 175 235), kenti Herakleia ve Amastris ile birlikte Pontos kentleri arasında gösterirken, Athenaios (M.S. II Yüzyıl sonu M.S. III Yüzyıl başı) Pontos kenti ve Miletos kolonisi olarak tasvir etmişlerdir. M.S. II Yüzyılda yaşamış olan Tralleisli Phlegon ise bir isim listesinde "Pontos ve Bithynia'dan bir kent olarak nitelediği Tios'un ethikon'unu Tianos ve Tiane olarak vermektedir.

Ammianus Marcellinus (M.S. 322 400) kentin adını diğer Pontos ve Paphlagonia kentleri yerleştiği, diğer bölge kentleri gibi kökeninin Helenler'in aktivitelerinden aldığını belirtmiştir.

Arrianos (M.S. II Yüzyıl) burasını "Helenler'in Ion kökenli kenti" ve "Miletoslular'ın kolonisi olarak nitelemiştir. M.S. VI. Yüzyıl edebiyatçılarından Byzantionlu Stephanos da kenti "Pontos'un Paphlagonia kenti" olarak zikretmiştir.

Konstantinos Porphyrogennitos (M.S. 905-959) eserinin farklı bölümlerinde Tiosve Tieion formunu kullanmakla kalmamış ayrıca üçüncü bir form olarak Teion'u da bunların yanına eklemiştir. Roma dönemi yazıtlarında kentin adı Teios, Tianos ve Teianos, Bizans dönemi mühürlerinde ise kentin adının Tios ve Tianos olduğu görülmektedir.

Çalışmada kullanılan verilen ölçüldüğü bölge Şekil 4.2'de görülmektedir.



Şekil 4.2. Filyos deniz yöresi ölçüm bölgesi

4.2. Araştırmanın Kapsamı ve Metodolojisi

Çalışma kapsamında Filyos Deniz Yöresi'nde DLH tarafından 1995 ve 1996 yıllarında ölçülmüş dalga yüksekliği verileri bilgisayar ortamına aktarılmıştır. Ölçümler 2 yıl boyunca 2' şer saat aralıklarla ölçülmüş ve yaklaşık 8000 adet dalga yüksekliği verisi kayıtlara geçmiştir. Kayda geçen veriler H_s , $H_{1/10}$, H_{ort} , H_{max} parametreleri şeklinde düzenlendiğinde ise toplamda 32000 adet veri elde edilmiş ve bu veri setleri ile iki yapay zekâ yöntemi kullanılarak dalga yüksekliği tahmin modeli yapılmıştır.

Bu veriler ile çeşitli modeller oluşturulmuş ve ilk olarak yapay sinir ağları ile modelleme gerçekleştirilmiştir. İkinci olarak ise esnek bir yapıya sahip olan bulanık sinir ağları kullanılmıştır. Her iki yöntemde Matlab R2014b programı ile çözülmüştür. Model sonuçları gerçek dalga verileri ile karşılaştırılmış ve iki yöntem için de sonuçlar sunulmuştur.

4.3. Araştırma Verilerinin Analizi

Verilerin analizinde ANN ve ANFIS teknikleri kullanılmıştır. Derlenen veriler ile 7 adet model oluşturulmuştur. Oluşturulan modeller zaman gecikmeli modellerdir. Dalga yüksekliği (H) ve dalga periyodu (T) kombinasyonlu olarak geciktirilmiş ve analizler yapılmıştır. Aşağıda bir zaman gecikmeli model örneği aşağıda görülmektedir;

$$H_{s(t-2)} + H_{s(t-1)} + T_{s(t-1)} \Rightarrow H_s$$

Bu modelde 2 dalga yüksekliği ve 1 dalga periyodu olarak toplamda 3 adet giriş parametresi kullanılmış ve H_s dalga yüksekliği çıktı olarak alınmıştır. $H_s = 06:00-08:00$ saatleri arasındaki dalga yüksekliği ise $\Rightarrow H_{s(t-1)} = 04:00-06:00$ saatleri arası, $H_{s(t-2)} = 02:00-04:00$ saatleri arası dalga yüksekliği, $T_{s(t-1)} = 04:00-06:00$ saatleri arası dalga periyodudur.

Bu çalışma için oluşturulan modeller aşağıda listelenmiştir (Çizelge 4.1) ;

Çizelge 4.1. Oluşturulan zaman gecikmeli H_s model yapıları

Model Adı	Kısaltılmış Model Adı	Model Yapısı
<i>Model – 1</i>	<i>H1T1</i>	$H_{s(t-1)}, T_{s(t-1)}$
<i>Model – 2</i>	<i>H1T2</i>	$T_{s(t-2)}, H_{s(t-1)}, T_{s(t-1)}$
<i>Model – 3</i>	<i>H2</i>	$H_{s(t-2)}, H_{s(t-1)}$
<i>Model – 4</i>	<i>H2T1</i>	$H_{s(t-2)}, H_{s(t-1)}, T_{s(t-1)}$
<i>Model – 5</i>	<i>H3</i>	$H_{s(t-3)}, H_{s(t-2)}, H_{s(t-1)}$
<i>Model – 6</i>	<i>H3T1</i>	$H_{s(t-3)}, H_{s(t-1)}, T_{s(t-1)}$
<i>Model – 7</i>	<i>H5</i>	$H_{s(t-5)}, H_{s(t-3)}, H_{s(t-1)}$

Modeller çalışmada tahmini gerçekleştirilen 4 parametre ($H_s, H_{1/10}, H_{ort}, H_{max}$) için de kullanılmıştır. 7 adet model için birçok üyelik fonksiyonu ve dilsel terim kombinasyonu oluşturulmuştur. Eldeki yaklaşık 8000 verinin 5500'ü eğitim için, 2500'ü ise test aşaması için kullanılmıştır. Modeller ANN ve ANFIS içerisinde eğitime tabi tutulmuştur. Elde edilen hata sonuçları ve tahmin etkinliğine bağlı olarak diğer kombinasyona ve modele geçiş yapılmaktadır. Geliştirilen modellerin temel özellikleri ve model detayları Bölüm 5'te verilecektir.

4.3.1. Bulanık sinir ağları (ANFIS) ile modelleme

ANFIS modelinin, bulanık mantık ve yapay sinir ağları yöntemlerine göre ön plana çıkan en önemli özelliklerinden birisi, girdi değişkenlerine ait üyelik fonksiyonlarının belirlenmesinde veri setinin kullanılması ve en uygun yapının veri setine bağlı oluşturulabilmesidir. Modelleme aşamasında zaman gecikmeli modeller kullanılmıştır.

Geriye yayma ve hibrit olmak üzere iki tip optimizasyon metodu kullanılmıştır. Geliştirilen modellerde hibrit metodunun geriye yayma metoduna oranla daha düşük hata oranları verdiği görülmüştür.

Bölüm 5'te her parametre ve her model için kullanılan üyelik fonksiyonları ve dilsel terim sayılarından bazıları ile denemeler ve bu denemeler sonunda ulaşılan korelasyon katsayıları ve hata oranları eğitim ve test aşaması için verilmiştir.

4.3.2. Yapay sinir ağları (ANN) ile modelleme

Yapay sinir ağlarının en güçlü yanı öğrenbilme yetenekleridir. Sisteme girdi değerleri verildikten sonra, örneklerdeki parametreler arasındaki ilişkiyi sistemin kendi kendisine öğrenmesi beklenir.

Genel olarak ağ yapısına göre ileri beslemeli ve geri beslemeli olarak sınıflandırılabilir. Çalışmalarda, ileri beslemeli yapay sinir ağları kullanılmıştır. İleri beslemeli yapay sinir ağları en yaygın kullanılan yapay sinir ağlarıdır.

Bölüm 5'te her parametre ve her model için kullanılan ağ yapısı, öğrenme fonksiyonu, transfer fonksiyonları, katman ve nöron sayıları ile oluşturulan modellerin analizleri ve bu analizler sonunda ulaşılan korelasyon katsayıları ve hata oranları eğitim ve test aşaması için verilmiştir.

5. BULGULAR

5.1. ANFIS ile Modelleme Bulguları

Her parametre ve modelleri için kullanılan üyelik fonksiyonları, dilsel terim sayıları ve öğrenme metotları ile denemeler ve bu denemeler sonunda bulunan korelasyon katsayıları ve hata oranları, eğitim ve test aşamaları için aşağıdaki çizelgelerde verilmiştir (Çizelge 5.1, 5.2, 5.3, 5.4);

Çizelge 5.1. H_s parametresi ANFIS modelleme sonuçları

Model	Operations				Errors of Models				Correlations	
	MF	Oper. Meth.	# of MF	Epochs	RMSE of TRA	RMSE of TEST	MAE of TRA	MAE of TEST	Corr. Tra.	Corr. Test
H1T1	trimf	hybrid	2 2	100	3,40%	3,17%	1,90%	1,79%	92,82%	89,91%
	trimf	backp.	2 2	1000	3,44%	3,21%	1,88%	1,77%	92,81%	89,89%
	trapmf	hybrid	2 2	100	3,41%	3,18%	1,93%	1,81%	92,75%	89,83%
	gbellmf	hybrid	2 2	100	3,40%	3,16%	1,90%	1,79%	92,81%	89,96%
H1T2	pimf	hybrid	2 2	500	3,39%	3,16%	1,91%	1,79%	92,83%	89,96%
	trimf	hybrid	2 2 2	100	3,33%	3,17%	1,87%	1,80%	93,08%	89,90%
	trapmf	hybrid	2 2 2	100	3,32%	3,18%	1,88%	1,81%	93,12%	89,88%
	pimf	hybrid	2 2 2	300	3,29%	3,19%	1,85%	1,79%	93,24%	89,80%
H2	gauss	hybrid	3 3 3	100	3,27%	3,19%	1,85%	1,80%	93,33%	89,81%
	trimf	hybrid	8 8 8	100	3,18%	3,23%	1,81%	1,81%	93,69%	89,59%
	trimf	hybrid	2 2	100	3,30%	3,19%	1,86%	1,79%	93,11%	89,82%
	trapmf	hybrid	2 2	100	3,38%	3,20%	1,92%	1,82%	92,88%	89,73%
H2T1	trimf	hybrid	7 7	100	3,22%	3,11%	1,83%	1,78%	93,53%	90,26%
	trimf	hybrid	2 2 2	100	3,32%	3,18%	1,85%	1,80%	93,14%	89,86%
	gbellmf	hybrid	2 2 2	100	3,28%	3,15%	1,84%	1,78%	93,28%	90,04%
	gauss	hybrid	2 2 2	100	3,30%	3,18%	1,85%	1,80%	93,21%	89,88%
H2T1	trimf	hybrid	4 4 4	100	3,21%	3,14%	1,82%	1,78%	93,56%	90,10%
	trapmf	hybrid	4 4 4	100	3,26%	3,12%	1,86%	1,80%	93,38%	90,19%
	gbellmf	hybrid	4 4 4	100	3,21%	3,17%	1,81%	1,78%	93,58%	89,94%
H3	trimf	hybrid	2 2	100	3,34%	3,16%	1,86%	1,78%	93,06%	89,96%
	trimf	hybrid	8 8	100	3,21%	3,11%	1,81%	1,77%	93,58%	90,26%
H3T1	trimf	hybrid	2 2 2	100	3,32%	3,15%	1,86%	1,78%	93,12%	90,02%
	trapmf	hybrid	2 2 2	100	3,36%	3,17%	1,90%	1,80%	92,98%	89,92%
	gbellmf	hybrid	5 5 5	200	3,15%	3,15%	1,79%	1,80%	94,84%	93,66%
H5	pimf	hybrid	4 4 4	100	3,24%	3,16%	1,83%	1,79%	93,45%	90,02%
	trimf	hybrid	2 2 2	100	3,31%	3,16%	1,85%	1,78%	93,18%	89,98%
	gauss2	hybrid	2 2 2	300	3,28%	3,14%	1,84%	1,78%	93,31%	90,12%
H5	trimf	hybrid	4 4 4	100	3,22%	3,14%	1,82%	1,78%	93,54%	90,12%
	trimf	hybrid	6 6 6	100	3,13%	3,87%	1,77%	1,84%	94,94%	93,03%

Çizelge 5.2. $H_{1/10}$ parametresi ANFIS modelleme sonuçları

Model	Operations				Errors of Models				Correlations	
	MF	Oper Meth.	# of MF	Epochs	RMSE of TRA	RMSE of TEST	MAE of TRA	MAE of TEST	Corr. Tra	Corr. Test
H1T1	trimf	hybrid	2 2	100	3,63%	3,38%	2,02%	1,92%	92,37%	89,33%
	gbellmf	hybrid	3 3	200	3,58%	3,36%	2,02%	1,94%	92,58%	89,46%
H1T2	trimf	hybrid	4 4	100	3,59%	3,37%	2,02%	1,93%	92,53%	89,38%
	trimf	backp.	2 2 2	2500	3,67%	3,45%	2,27%	2,17%	92,39%	89,28%
H1T2	trimf	hybrid	3 3 3	100	3,55%	3,40%	1,99%	1,94%	92,69%	89,28%
	gbellmf	hybrid	3 3 3	100	3,51%	3,38%	1,98%	1,93%	92,85%	89,36%
H2	gauss	hybrid	3 3 3	200	3,49%	3,40%	1,97%	1,93%	92,94%	89,23%
	gauss	hybrid	2 2 2	200	3,54%	3,40%	1,99%	1,94%	92,72%	89,24%
H2	trimf	hybrid	2 2	100	3,57%	3,41%	1,99%	1,93%	92,60%	89,18%
	gbellmf	hybrid	2 2	800	3,52%	3,37%	1,98%	1,92%	92,81%	89,44%
H2	pimf	hybrid	2 2	500	3,51%	3,35%	1,97%	1,92%	92,84%	89,50%
	pimf	hybrid	4 4	500	3,46%	3,33%	1,95%	1,93%	93,07%	89,65%
H2	trapmf	hybrid	2 2 2	100	3,59%	3,40%	2,04%	1,95%	92,51%	89,20%
	trapmf	backp.	2 2 2	1000	3,65%	3,45%	2,24%	2,16%	92,46%	89,27%
T1	gbellmf	hybrid	3 3 3	200	3,46%	3,35%	1,96%	1,93%	93,06%	89,54%
	gbellmf	hybrid	5 5 5	100	3,37%	3,36%	1,91%	1,92%	93,39%	89,47%
H3	trimf	hybrid	2 2	100	3,58%	3,38%	2,00%	1,93%	92,58%	89,32%
	trapmf	hybrid	2 2	100	3,61%	3,40%	2,04%	1,96%	92,46%	89,21%
H3	trimf	hybrid	3 3	100	3,54%	3,37%	1,98%	1,92%	92,72%	89,45%
	gauss	hybrid	5 5	100	3,50%	3,36%	1,97%	1,93%	92,91%	89,49%
H3	trimf	hybrid	12 12	100	3,35%	3,27%	1,91%	1,93%	94,84%	91,95%
	trimf	hybrid	22 22	100	3,18%	3,87%	1,83%	1,98%	95,26%	91,83%
H3	trimf	hybrid	2 2 2	100	3,55%	3,37%	1,98%	1,93%	92,67%	89,42%
	trapmf	hybrid	2 2 2	100	3,58%	3,39%	2,02%	1,94%	92,56%	89,28%
T1	gauss	hybrid	2 2 2	200	3,58%	3,38%	1,98%	1,93%	92,75%	89,40%
	trimf	hybrid	3 4 5	100	3,49%	3,37%	1,97%	1,94%	92,93%	89,40%
H5	trimf	hybrid	2 2 2	100	3,54%	3,38%	1,98%	1,93%	92,73%	89,36%
	trapmf	hybrid	2 2 2	100	3,57%	3,39%	2,03%	1,96%	92,62%	89,30%
H5	gauss	hybrid	2 2 2	400	3,53%	3,37%	1,99%	1,94%	92,77%	89,43%
	trimf	hybrid	3 3 3	100	3,51%	3,36%	1,97%	1,92%	92,87%	89,50%
H5	gbellmf	hybrid	3 3 3	500	3,45%	3,35%	1,96%	1,94%	93,08%	89,52%
	gbellmf	hybrid	5 5 5	100	3,35%	3,42%	1,92%	1,94%	94,94%	93,26%

Çizelge 5.3. H_{ort} parametresi ANFIS modelleme sonuçları

Model	Operations				Errors of Models				Correlations	
	MF	Oper. Meth.	# of MF	Epochs	RMSE of TRA	RMSE of TEST	MAE of TRA	MAE of TEST	Corr. Tra	Corr. Test
H1	trimf	hybrid	2 2	100	3,32%	3,10%	1,84%	1,74%	92,99%	90,01%
	trimf	backp.	2 2	200	3,38%	3,16%	2,08%	1,97%	92,95%	90,06%
T1	trimf	hybrid	3 3	100	3,31%	3,07%	1,84%	1,73%	93,03%	90,20%
	trapmf	hybrid	2 2	100	3,34%	3,12%	1,88%	1,78%	92,87%	89,87%
H1T	trimf	hybrid	3 3 3	100	3,27%	3,09%	1,83%	1,75%	93,18%	90,09%
	gauss	hybrid	3 3 3	100	3,20%	3,06%	1,82%	1,74%	93,46%	90,32%
H2	gauss2	hybrid	3 3 3	100	3,23%	3,12%	1,82%	1,76%	93,35%	89,92%
	trimf	hybrid	2 2	100	3,24%	3,12%	1,79%	1,74%	93,31%	89,91%
H2	gbellmf	hybrid	2 2	500	3,20%	3,09%	1,78%	1,72%	93,46%	90,09%
	trimf	hybrid	3 3	100	3,20%	3,09%	1,78%	1,73%	93,48%	90,09%
H2T	gauss	hybrid	3 3	100	3,17%	3,10%	1,78%	1,73%	93,58%	90,08%
	trimf	hybrid	3 3 3	100	3,18%	3,09%	1,78%	1,73%	93,57%	90,12%
H2	gbellmf	hybrid	3 3 3	100	3,15%	3,09%	1,76%	1,73%	93,67%	90,10%
	gauss2	hybrid	3 3 3	100	3,15%	3,09%	1,76%	1,73%	93,67%	90,10%
T1	gauss2	backp.	3 3 3	5000	3,49%	3,21%	2,20%	2,06%	92,58%	89,83%
	trimf	hybrid	2 2 2	100	3,22%	3,12%	1,79%	1,74%	93,37%	89,92%
H3	trapmf	hybrid	2 2 2	100	3,28%	3,13%	1,85%	1,78%	93,12%	89,87%
	pimf	hybrid	3 3	100	3,19%	3,08%	1,78%	1,73%	93,49%	90,16%
H3	trimf	hybrid	2 2	100	3,25%	3,09%	1,80%	1,73%	93,26%	90,09%
	trimf	backp.	2 2	2000	3,35%	3,21%	2,14%	2,08%	93,20%	90,02%
H3	trimf	hybrid	11 11	100	3,06%	3,05%	1,73%	1,73%	94,01%	90,32%
	trimf	hybrid	22 22	100	2,90%	3,02%	1,67%	1,73%	94,63%	90,55%
H3	trapmf	hybrid	3 3 3	100	3,21%	3,09%	1,81%	1,75%	93,45%	90,14%
	pimf	hybrid	3 3 3	100	3,18%	3,08%	1,77%	1,72%	93,57%	90,17%
T1	gbellmf	hybrid	4 4 4	100	3,13%	3,15%	1,75%	1,74%	93,76%	89,73%
	trimf	hybrid	4 4 4	100	3,17%	3,09%	1,76%	1,72%	93,58%	90,14%
H5	gbellmf	hybrid	3 3 3	200	3,15%	3,10%	1,76%	1,72%	93,67%	90,09%
	gauss	hybrid	3 3 3	100	3,16%	3,08%	1,76%	1,72%	93,62%	90,17%
H5	gauss2	hybrid	3 3 3	100	3,16%	3,08%	1,76%	1,71%	93,62%	90,17%
	trimf	hybrid	4 4 4	100	3,16%	3,08%	1,76%	1,73%	93,65%	90,19%
H5	trapmf	hybrid	4 4 4	100	3,18%	3,10%	1,79%	1,75%	93,54%	90,07%
	gauss	hybrid	4 4 4	100	3,13%	3,11%	1,75%	1,73%	93,77%	89,98%
H5	gauss	hybrid	5 5 5	100	3,08%	3,06%	1,72%	1,72%	93,94%	90,32%
	gauss	hybrid	8 8 8	10	2,95%	3,45%	1,65%	1,73%	95,52%	93,00%
H5	trapmf	hybrid	6 6 6	100	3,06%	3,22%	1,71%	1,75%	94,04%	89,38%


Çizelge 5.4. H_{max} parametresi ANFIS modelleme sonuçları

Model	Operations				Errors of Models				Correlations	
	MF	Oper. Meth.	# of MF	Epochs	RMSE of TRA	RMSE of TEST	MAE of TRA	MAE of TEST	Corr. Tra	Corr. Test
H1	trimf	hybrid	3 3	100	4,52%	4,46%	2,55%	2,52%	89,12%	83,64%
T1	gauss2	hybrid	5 5	100	4,45%	4,50%	2,54%	2,55%	89,48%	83,39%
H1	trimf	hybrid	3 3 3	100	4,48%	4,43%	2,53%	2,51%	89,33%	83,87%
T1	gauss	hybrid	3 3 3	100	4,40%	4,40%	2,52%	2,51%	89,68%	84,03%
H2	gauss2	hybrid	3 3 3	100	4,41%	4,41%	2,52%	2,50%	89,63%	84,04%
H2	gbellmf	hybrid	3 3	300	4,43%	4,42%	2,53%	2,55%	89,55%	83,85%
H2	gbellmf	backp.	3 3	1000	4,67%	4,64%	2,90%	2,84%	88,71%	82,85%
H2	gbellmf	hybrid	15 15	100	4,05%	4,28%	2,36%	2,48%	91,29%	84,83%
H2	trimf	hybrid	3 3 3	100	4,45%	4,41%	2,53%	2,53%	89,48%	83,96%
T2	gbellmf	hybrid	3 5 5	100	4,30%	4,37%	2,46%	2,50%	90,15%	84,25%
H1	gauss2	hybrid	4 4 4	100	4,33%	4,35%	2,49%	2,51%	90,01%	84,42%
H1	dsigmf	hybrid	4 4 4	200	4,35%	4,40%	2,50%	2,52%	89,92%	84,03%
H1	trimf	hybrid	5 5	100	4,47%	4,47%	2,53%	2,51%	89,37%	83,53%
H3	gbellmf	hybrid	8 8	100	4,39%	4,42%	2,50%	2,53%	89,76%	83,87%
H3	gauss2	hybrid	4 4	200	4,50%	4,47%	2,55%	2,54%	89,24%	83,57%
H3	trimf	hybrid	10 10	100	4,33%	4,39%	2,48%	2,53%	90,03%	84,04%
H3	trimf	hybrid	4 4 4	100	4,39%	4,41%	2,50%	2,53%	89,77%	83,98%
T3	gauss2	hybrid	4 4 4	100	4,38%	4,40%	2,49%	2,51%	89,77%	84,02%
H1	pimf	hybrid	6 6 6	100	4,32%	4,37%	2,48%	2,52%	90,05%	84,24%
H1	trimf	hybrid	3 3 3	100	4,43%	4,41%	2,53%	2,54%	89,57%	83,97%
H1	gbellmf	hybrid	3 3 3	200	4,38%	4,36%	2,52%	2,53%	89,80%	84,30%
H5	gauss	hybrid	4 4 4	100	4,35%	4,34%	2,51%	2,53%	89,96%	84,48%
H5	pimf	hybrid	5 5 5	100	4,27%	4,29%	2,47%	2,52%	90,29%	84,74%
H5	gauss	hybrid	8 8 8	100	3,94%	4,28%	2,50%	2,47%	92,87%	88,67%
H5	gbellmf	hybrid	5 3 4	100	4,26%	4,24%	2,47%	2,50%	90,33%	85,11%

Her parametre kendi içerisindeki model tipleri ile kıyaslandığında yaklaşık olarak aynı sonuçları verdiği görülmüştür. En tutarlı modellerin seçiminde kıyaslama ölçütü olarak sadece bu çizelgelerde görülen değerler kullanılmamış, modelin 3 boyutlu sistem analizi ve gerçek değerler ile tahmin değerlerinin saçılma grafikleri de etkili olmuştur.

5.1.1. H_s parametresi

H_s parametresi için tüm istatistiksel sonuçlar ve 3 boyutlu sistem analiz çıktıları karşılaştırıldığında Model-6 yani “H3T1” modeli en doğru ve güvenilir sonuçları vermektedir. Seçilen model kombinasyonunda Gumbell üyelik fonksiyonu kullanılmıştır. Bulanık dilsel terim sayısı ise her bir giriş parametresi için 5 olarak seçilmiştir. Toplamda 3 adet giriş parametresi ve 1 adet çıkış parametresi vardır. Ayrıca optimizasyon metodu olarak hibrit optimizasyon metodu kullanılmıştır. Bu analiz sistemi Şekil 5.1’de gösterilmiştir;



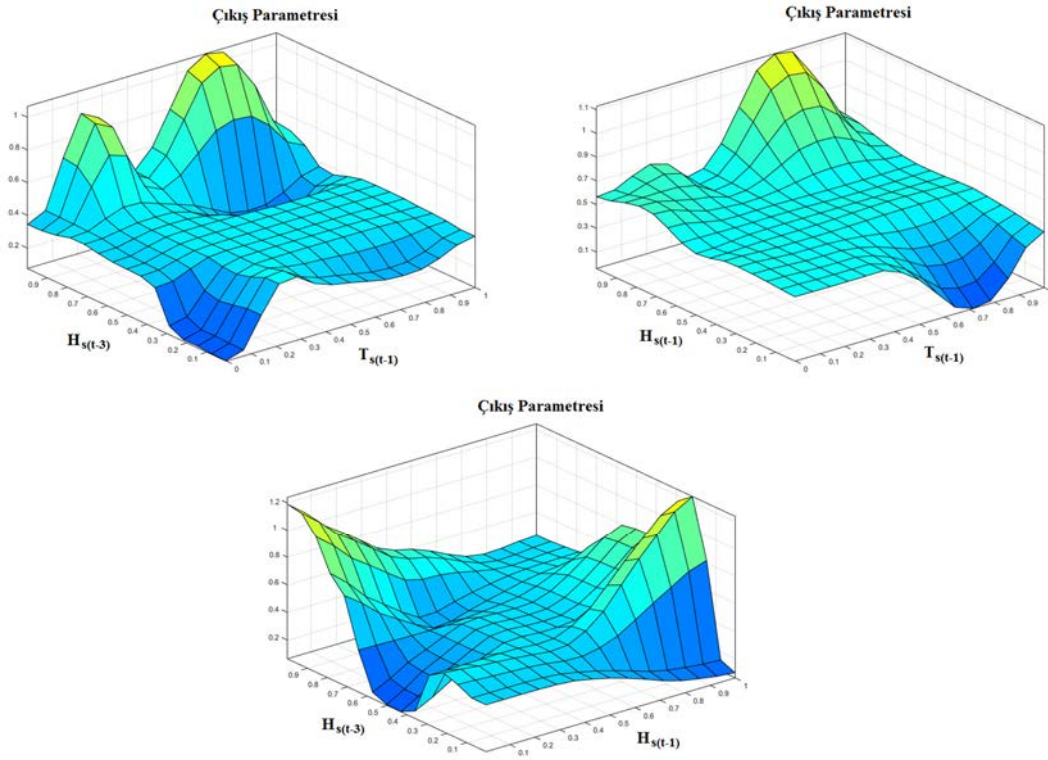
Şekil 5.1. H_s parametresi ANFIS analiz sistemi mimari yapısı

Aşağıdaki çizelgede bu analiz sistemi için kullanılan (Çizelge 5.5) giriş parametresi, çıkış parametresi, kullanılan dilsel terim ve üyelik fonksiyonu tek tablo halinde belirtilmiştir.


Çizelge 5.5. H_s parametresi seçilen ANFIS modeli

Tahmin Parametresi	Model	Giriş Parametresi	Çıkış Parametresi	Kullanılan Dilsel Terim	Kullanılan Üyelik Fonk.
H_s	Model-6	0-1	0-1	5	Gumbell

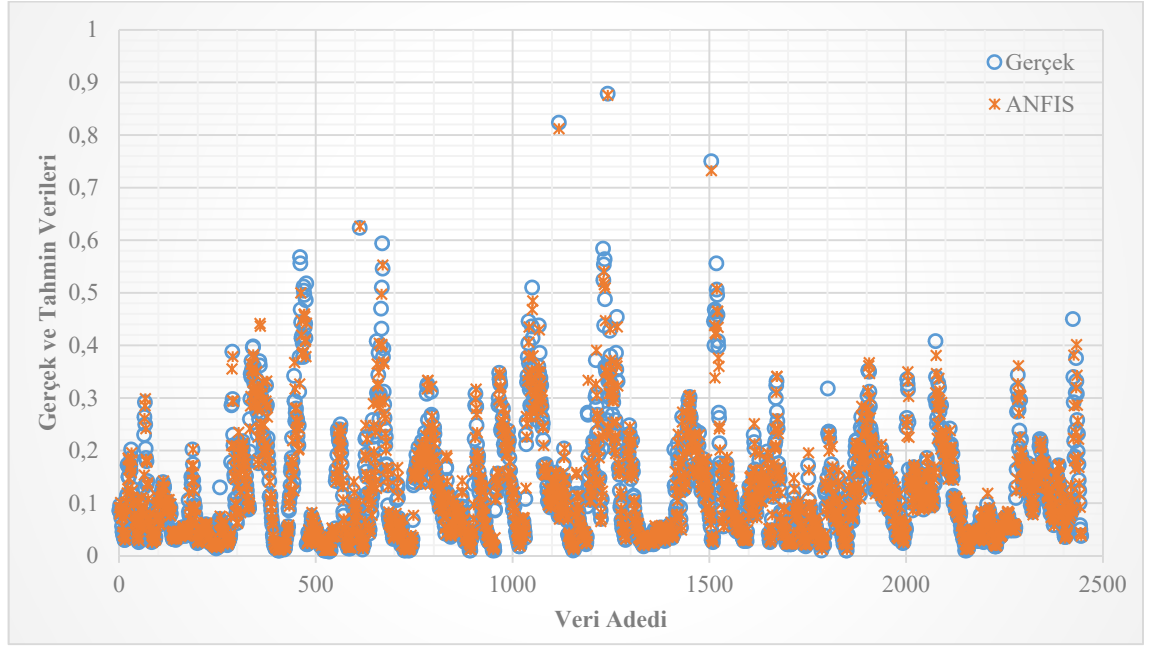
Çalışmada etkili olan bulanık dilsel terimlerin kullanımından oluşan bulanık sistem durulaştırılarak sayısal sonuçlar elde edilmiştir. Şekil 5.2’de gösterilen Filyos Bölgesi belirgin dalga yüksekliği için oluşturulan üç boyutlu sistem hangi andaki tahmin isteniyor ise bunu sayısal sonuç olarak sağlamaktadır.

Şekil 5.2. Filyos Bölgesi H_s parametresi ANFIS 3D sistem analizi

Şekil 5.3’te belirgin dalga yüksekliği için ANFIS modeli eğitim aşamasında elde edilen tahminler verilmiştir. Eğitim aşamasında model ortalama %3.15 hata oranı ile tahmin gerçekleştirmiştir. Şekil 5.4’te belirtilen ise modelin test aşamasıdır ve ortalama hata oranı %3.15 olarak bulunmuştur.



Şekil 5.3. ANFIS modeli H_s parametresi eğitim aşaması



Şekil 5.4. ANFIS modeli H_s parametresi test aşaması

Çalışmada eğitim ve test aşaması için ortalama hata oranları MAE ve RMSE hata parametreleri ile hesaplanmıştır.


Çizelge 5.6'da bu değerler verilmiştir;


Çizelge 5.6. H_s eğitim ve test aşaması ortalama hata oranları

Model	HATA PARAMETRELERİ			
	MAE		RMSE	
	Eğitim	Test	Eğitim	Test
H3T1	% 1.79	% 1.80	% 3.15	% 3.15

Eğitim ve test aşamasında gerçek değerler ile tahmin değerleri arasındaki ilişkiyi belirlemek üzere korelasyon analizi yapılmıştır. İki değişken arasındaki doğrusal ilişkinin gücünü ve yönünü belirlemek için hesaplanan katsayıya “Korelasyon katsayısı (R^2)” denilmektedir.

R^2 değeri 0 ile 1 arasında bir değer alır. Bu aralıktaki değerler iki veri arasında bir ilişki olduğunu belirtir. Bu değerın 1'e yakınlığı aradaki ilişkinin mükemmelliğini göstermektedir.

Şekil 5.5. H_s parametresi (ANFIS) eğitim aşaması saçılma diyagramı ve R^2 değeri




Şekil 5.6. H_s parametresi (ANFIS) test aşaması saçılma diyagramı ve R^2 değeri

Şekil 5.5 ve 5.6’da görüldüğü üzere gerçek veriler ve tahmin verileri arasındaki ilişki verilmiştir. Kullanılan model için eğitim aşamasında $R^2=0.95$, test aşamasında ise $R^2=0.94$ bulunmuştur.

5.1.2. $H_{1/10}$ parametresi

$H_{1/10}$ parametresi için tüm istatistiksel sonuçlar ve 3 boyutlu sistem analizi çıktıları karşılaştırıldığında Model-7 yani “H5” modeli en doğru ve güvenilir sonuçları vermektedir. Seçilen model kombinasyonunda Gumbell üyelik fonksiyonu kullanılmıştır. Bulanık dilsel terim sayısı ise her bir giriş parametresi için 5 olarak seçilmiştir. Toplamda 3 adet giriş parametresi ve 1 adet çıkış parametresi vardır. Ayrıca optimizasyon metodu olarak hibrit optimizasyon metodu kullanılmıştır. Bu analiz sistemi Şekil 5.7’de gösterilmiştir;



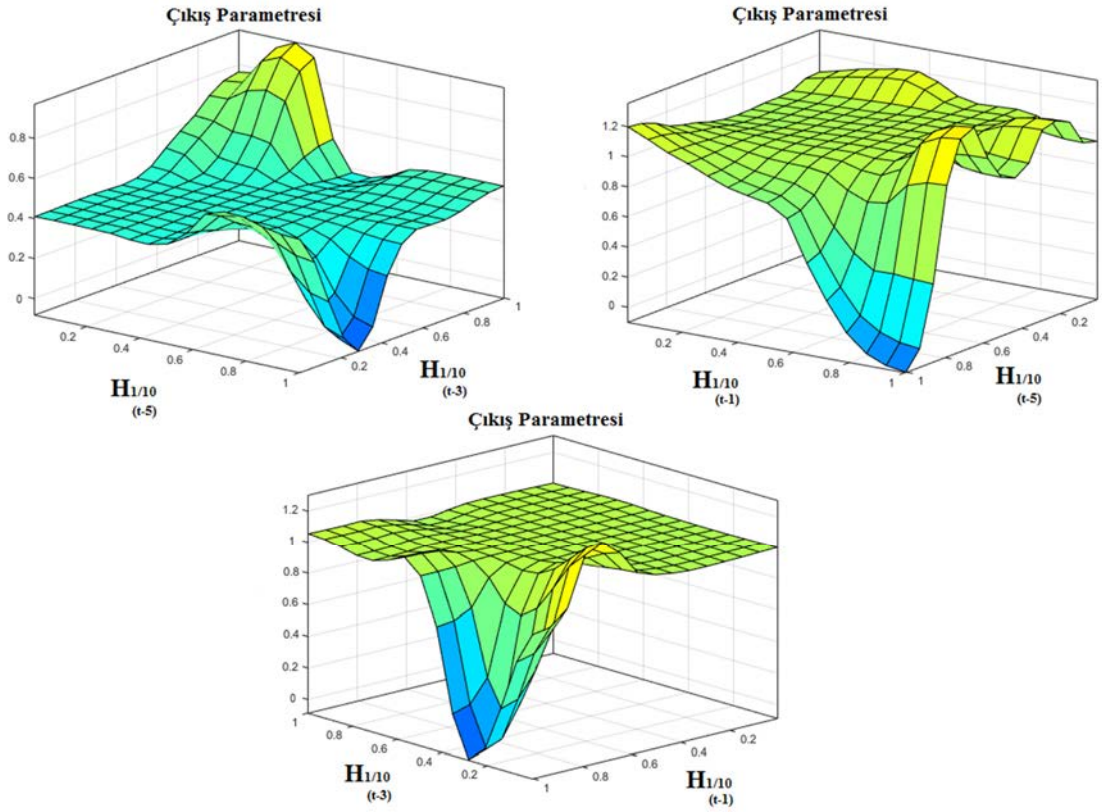
Şekil 5.7. $H_{1/10}$ parametresi ANFIS analiz sistemi mimari yapısı

Aşağıdaki çizelgede bu analiz sistemi için kullanılan (Çizelge 5.7) giriş parametresi, çıkış parametresi, kullanılan dilsel terim ve üyelik fonksiyonu tek tablo halinde belirtilmiştir.

Çizelge 5.7. $H_{1/10}$ parametresi seçilen ANFIS modeli


Tahmin Parametresi	Model	Giriş Parametresi	Çıkış Parametresi	Kullanılan Dilsel Terim	Kullanılan Üyelik Fonk.
$H_{1/10}$	Model-7	0-1	0-1	5	Gumbell

Çalışmada etkili olan bulanık dilsel terimlerin kullanımından oluşan bulanık sistem durulaştırılarak sayısal sonuçlar elde edilmiştir. Şekil 5.8’de gösterilen Filyos Bölgesi $H_{1/10}$ dalga yüksekliği için oluşturulan üç boyutlu sistem hangi andaki tahmin isteniyor ise bunu sayısal sonuç olarak sağlamaktadır.




Şekil 5.8. Filyos Bölgesi $H_{1/10}$ parametresi ANFIS 3D sistem analizi

Şekil 5.9’da $H_{1/10}$ için ANFIS modeli eğitim aşamasında elde edilen tahminler verilmiştir. Eğitim aşamasında model ortalama %3.35 hata oranı ile tahmin gerçekleştirmiştir. Şekil 5.10’da belirtilen ise modelin test aşamasıdır ve ortalama hata oranı %3.42 olarak bulunmuştur.



Şekil 5.9. ANFIS modeli $H_{1/10}$ parametresi eğitim aşaması



Şekil 5.10. ANFIS modeli $H_{1/10}$ parametresi test aşaması

Çalışmada eğitim ve test aşaması için ortalama hata oranları MAE ve RMSE hata parametreleri ile hesaplanmıştır.


Çizelge 5.8’de bu değerler verilmiştir;

Çizelge 5.8. $H_{1/10}$ eğitim ve test aşaması ortalama hata oranları


Model	HATA PARAMETRELERİ			
	MAE		RMSE	
	Eğitim	Test	Eğitim	Test
H5	% 1.92	% 1.94	% 3.35	% 3.42

Şekil 5.11 ve 5.12’de görüldüğü üzere gerçek veriler ve tahmin verileri arasındaki ilişki verilmiştir. Kullanılan model için eğitim aşamasında $R^2=0.95$, test aşamasında ise $R^2=0.93$ bulunmuştur.

$H_{1/10}$ parametresi de $H_{1/3}$ parametresi ile yaklaşık olarak aynı sonuçları vermiş ve kullanılan üyelik fonksiyonları ile dilsel terim sayıları da benzerlik göstermiştir.




Şekil 5.11. $H_{1/10}$ parametresi (ANFIS) eğitim aşaması saçılma diyagramı ve R^2 değeri



Şekil 5.12. $H_{1/10}$ parametresi (ANFIS) test aşaması saçılma diyagramı ve R^2 değeri

5.1.3. H_{ort} parametresi

H_{ort} parametresi için tüm istatistiksel sonuçlar ve 3 boyutlu sistem analizi çıktıları karşılaştırıldığında Model-7 yani “H5” modeli en doğru ve güvenilir sonuçları vermektedir. Seçilen model kombinasyonunda Gauss üyelik fonksiyonu kullanılmıştır. Bulanık dilsel terim sayısı ise her bir giriş parametresi için 8 olarak seçilmiştir. Toplamda 3 adet giriş parametresi ve 1 adet çıkış parametresi vardır. Ayrıca optimizasyon metodu olarak hibrit optimizasyon metodu kullanılmıştır. Bu analiz sistemi Şekil 5.13’de gösterilmiştir;



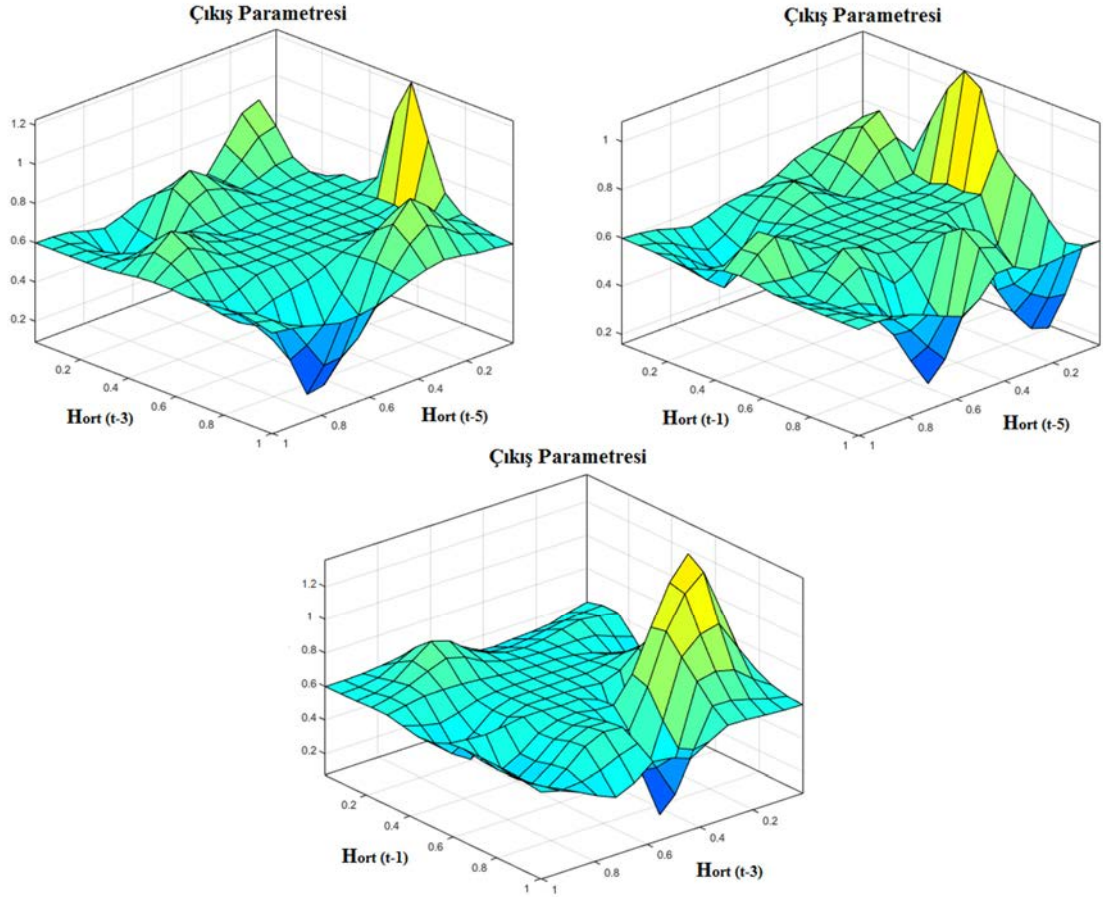
Şekil 5.13. H_{ort} parametresi ANFIS analiz sistemi mimari yapısı

Aşağıdaki çizelgede bu analiz sistemi için kullanılan (Çizelge 5.9) giriş parametresi, çıkış parametresi, kullanılan dilsel terim ve üyelik fonksiyonu tek tablo halinde belirtilmiştir.

Çizelge 5.9. H_{ort} parametresi seçilen ANFIS modeli


Tahmin Parametresi	Model	Giriş Parametresi	Çıkış Parametresi	Kullanılan Dilsel Terim	Kullanılan Üyelik Fonk.
H_{ort}	Model-7	0-1	0-1	8	Gauss

Çalışmada etkili olan bulanık dilsel terimlerin kullanımından oluşan bulanık sistem durulaştırılarak sayısal sonuçlar elde edilmiştir. Şekil 5.14'te gösterilen Filyos Bölgesi H_{ort} dalga yüksekliği için oluşturulan üç boyutlu sistem hangi andaki tahmin isteniyor ise bunu sayısal sonuç olarak sağlamaktadır.




Şekil 5.14. Filyos Bölgesi H_{ort} parametresi ANFIS 3D sistem analizi

Şekil 5.15'te H_{ort} için ANFIS modeli eğitim aşamasında elde edilen tahminler verilmiştir. Eğitim aşamasında model ortalama %2.95 hata oranı ile tahmin gerçekleştirmiştir. Şekil 5.16'da belirtilen ise modelin test aşamasıdır ve ortalama hata oranı %3.45 olarak bulunmuştur.



Şekil 5.15. ANFIS modeli H_{ort} parametresi eğitim aşaması





Şekil 5.16. ANFIS modeli H_{ort} parametresi test aşaması

Çalışmada eğitim ve test aşaması için ortalama hata oranları MAE ve RMSE hata parametreleri ile hesaplanmıştır. Çizelge 5.10'de bu değerler verilmiştir;

Çizelge 5.10. H_{ort} eğitim ve test aşaması ortalama hata oranları


Model	HATA PARAMETRELERİ			
	MAE		RMSE	
	Eğitim	Test	Eğitim	Test
H5	% 1.65	% 1.73	% 2.95	% 3.45

Şekil 5.17. H_{ort} parametresi (ANFIS) eğitim aşaması saçılma diyagramı ve R^2 değeriŞekil 5.18. H_{ort} parametresi (ANFIS) test aşaması saçılma diyagramı ve R^2 değeri

Şekil 5.17 ve 5.18’de görüldüğü üzere gerçek veriler ve tahmin verileri arasındaki ilişki verilmiştir. Kullanılan model için eğitim aşamasında $R^2=0.96$, test aşamasında ise $R^2=0.94$ bulunmuştur.

5.1.4. H_{max} parametresi

H_{max} parametresi için tüm istatistiksel sonuçlar ve 3 boyutlu sistem analizi çıktıları karşılaştırıldığında Model-7 yani “H5” modeli en doğru ve güvenilir sonuçları vermektedir. Seçilen model kombinasyonunda Gauss üyelik fonksiyonu kullanılmıştır. Bulanık dilsel terim sayısı ise her bir giriş parametresi için 8 olarak seçilmiştir. Toplamda 3 adet giriş parametresi ve 1 adet çıkış parametresi vardır. Ayrıca optimizasyon metodu olarak hibrit optimizasyon metodu kullanılmıştır. Bu analiz sistemi Şekil 5.19’da gösterilmiştir;



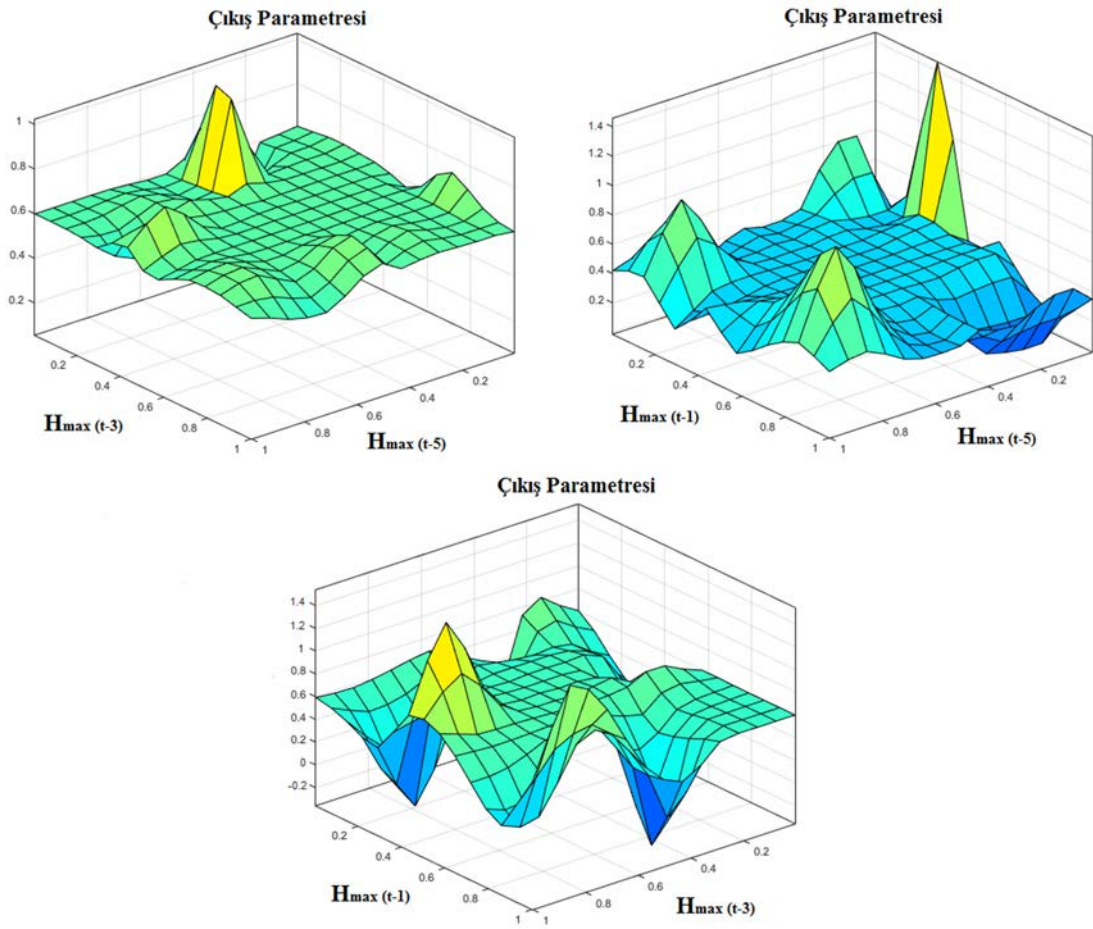
Şekil 5.19. H_{max} parametresi ANFIS analiz sistemi mimari yapısı

Aşağıdaki çizelgede bu analiz sistemi için kullanılan (Çizelge 5.11) giriş parametresi, çıkış parametresi, kullanılan dilsel terim ve üyelik fonksiyonu tek tablo halinde belirtilmiştir.


Çizelge 5.11. H_{max} parametresi seçilen ANFIS modeli

Tahmin Parametresi	Model	Giriş Parametresi	Çıkış Parametresi	Kullanılan Dilsel Terim	Kullanılan Üyelik Fonk.
H_{max}	Model-7	0-1	0-1	8	Gauss


Çalışmada etkili olan bulanık dilsel terimlerin kullanımından oluşan bulanık sistem durulaştırılarak sayısal sonuçlar elde edilmiştir. Şekil 5.20’de gösterilen Filyos Bölgesi H_{max} dalga yüksekliği için oluşturulan üç boyutlu sistem hangi andaki tahmin isteniyor ise bunu sayısal sonuç olarak sağlamaktadır.

Şekil 5.20. Filyos Bölgesi H_{max} parametresi ANFIS 3D sistem analizi

Şekil 5.21’de belirgin dalga yüksekliği için ANFIS modeli eğitim aşamasında elde edilen tahminler verilmiştir. Eğitim aşamasında model ortalama %3.94 hata oranı ile tahmin gerçekleştirmiştir. Şekil 5.22’de belirtilen ise modelin test aşamasıdır ve ortalama hata oranı %4.28 olarak bulunmuştur.



Şekil 5.21. ANFIS modeli H_{max} parametresi eğitim aşaması

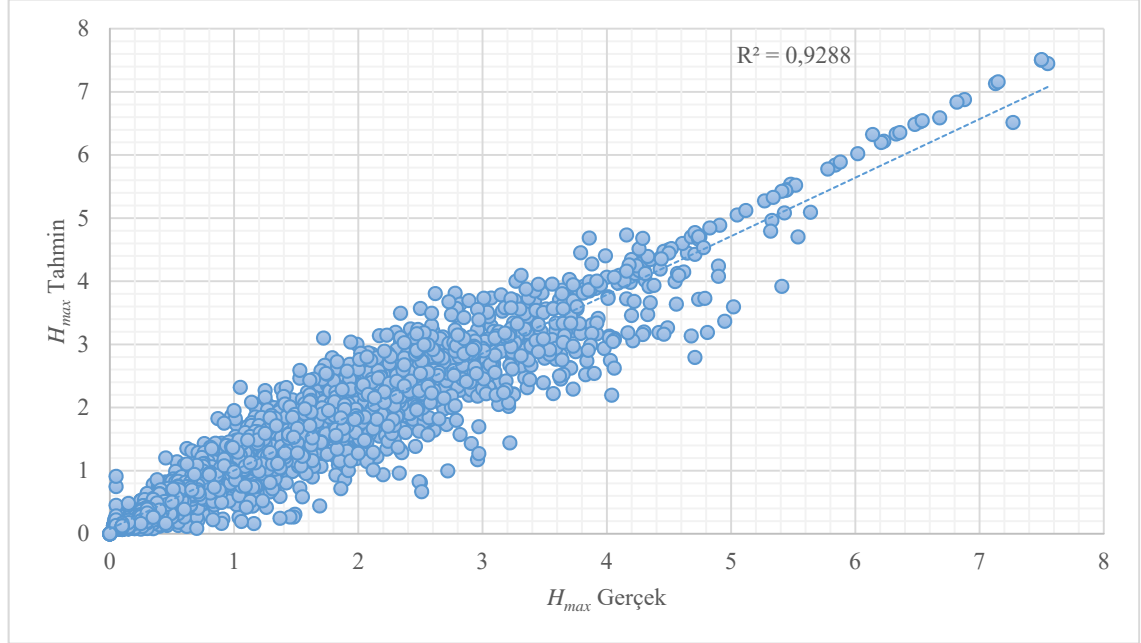


Şekil 5.22. ANFIS modeli H_{max} parametresi test aşaması


Çalışmada eğitim ve test aşaması için ortalama hata oranları MAE ve RMSE hata parametreleri ile hesaplanmıştır. Çizelge 5.12’de bu değerler verilmiştir;

Çizelge 5.12. H_{max} eğitim ve test aşaması ortalama hata oranları

Model	HATA PARAMETRELERİ			
	MAE		RMSE	
H5	Eğitim	Test	Eğitim	Test
	% 2.50	% 2.47	% 3.94	% 4.28



Şekil 5.23. H_{max} parametresi (ANFIS) eğitim aşaması saçılma diyagramı ve R^2 değeri



Şekil 5.24. H_{max} parametresi (ANFIS) test aşaması saçılma diyagramı ve R^2 değeri

Şekil 5.23 ve 5.24’te görüldüğü üzere gerçek veriler ve tahmin verileri arasındaki ilişki verilmiştir. Kullanılan model için eğitim aşamasında $R^2=0.93$, test aşamasında ise $R^2=0.89$ bulunmuştur.

5.2. ANN ile Modelleme Bulguları

Çalışmanın bu kısmında modelleme için yapay sinir ağları kullanılmıştır. Bu kısımda da ANFIS ile yapılan çalışmada kullanılan 7 adet model kullanılmıştır. Modeller ile ANN’de bulunan transfer fonksiyonları, öğrenme fonksiyonları, katman ve nöron sayılarıyla kombinasyonlar oluşturulmuştur. Bu kombinasyonlar yapay sinir ağları ile çözülmüş ve sonuçlar değerlendirilmiştir. Ara katman sayısı artırılarak ağın performansındaki değişimler incelenmiştir. Sonuçlar aşağıdaki çizelgelerde (Çizelge 5.13, 5.14, 5.15, 5.16) verilmiştir.

Çizelge 5.13. H_s parametresi ANN modelleme sonuçları

Model	Operations		Errors of Models					Correlations		
	Network Type	Trans. Funct.	# of L	# of N	RMSE of TRA	RMSE of TEST	MAE of TRA	MAE of TEST	Corr. Tra	Corr. Test
H1	feed-for. back.	t-p	2	2	3,41%	3,17%	1,91%	1,79%	92,78%	89,94%
T1	cascade-for. back.	t-t-p	3	3	3,35%	3,14%	1,89%	1,79%	93,03%	90,14%
H1	feed-for. back.	l-p	2	2	3,37%	3,18%	1,89%	1,81%	92,96%	89,85%
T2	feed-for. back.	t-t-t-p	4	4	3,34%	3,16%	1,87%	1,79%	93,09%	89,99%
H2	cascade-for. back.	t-p	2	2	3,30%	3,18%	1,83%	1,78%	93,24%	89,87%
H2	cascade-for. back.	t-t-t	3	3	3,25%	3,15%	1,83%	1,79%	93,44%	90,09%
H2	feed-for. back.	t-p	2	2	3,31%	3,16%	1,85%	1,79%	93,18%	90,00%
T1	feed-for. back.	t-t-t-p	4	2	3,26%	3,16%	1,83%	1,78%	93,40%	89,99%
H3	feed-for. back.	t-p	2	2	3,34%	3,19%	1,88%	1,80%	93,06%	89,87%
H3	cascade-for. back.	t-t-p	3	3	3,31%	3,16%	1,86%	1,78%	93,21%	90,05%
H3	cascade-for. back.	l-l-t-l-p	5	5	3,30%	3,16%	1,85%	1,77%	93,23%	90,02%
T1	feed-for. back.	l-l-p	3	3	3,33%	3,16%	1,90%	1,82%	94,62%	92,90%
H5	feed-for. back.	t-p	2	2	3,33%	3,18%	1,88%	1,81%	93,10%	89,91%
H5	feed-for. back.	t-t-t-p	4	4	3,29%	3,13%	1,84%	1,78%	93,29%	90,19%

Çizelge 5.14. $H_{1/10}$ parametresi ANN modelleme sonuçları

Model	Operations		Errors of Models						Correlations	
	Network Type	Trans. Funct.	# of L	# of N	RMSE of TRA	RMSE of TEST	MAE of TRA	MAE of TEST	Corr. Tra	Corr. Test
H1	feed-for. back.	t-p	2	2	3,63%	3,39%	2,04%	1,93%	92,39%	89,31%
T1	cascade-for. back.	t-t-p	3	3	3,56%	3,35%	2,01%	1,93%	92,39%	89,59%
H1	feed-for. back.	l-p	2	2	3,63%	3,38%	2,06%	1,93%	92,38%	89,38%
T2	feed-for. back.	t-t-t-p	4	4	3,56%	3,37%	2,02%	1,93%	92,65%	89,44%
H2	cascade-for. back.	t-p	2	2	3,60%	3,38%	2,01%	1,92%	92,52%	89,29%
	cascade-for. back.	t-t-t	3	3	3,52%	3,34%	1,98%	1,92%	94,48%	92,62%
H2	feed-for. back.	t-p	2	2	3,58%	3,42%	1,99%	1,94%	92,61%	89,22%
T1	feed-for. back.	t-t-t-p	4	2	3,55%	3,40%	1,99%	1,94%	92,72%	89,30%
H3	feed-for. back.	t-p	2	2	3,56%	3,37%	1,99%	1,92%	92,66%	89,42%
	cascade-for. back.	t-t-p	3	3	3,56%	3,37%	1,99%	1,92%	92,36%	89,37%
H3	cascade-for. back.	l-l-t-l-p	5	5	3,54%	3,36%	1,97%	1,91%	92,77%	89,47%
T1	feed-for. back.	l-l-p	3	3	3,56%	3,37%	1,97%	1,91%	92,68%	89,50%
H5	feed-for. back.	t-p	2	2	3,54%	3,38%	2,00%	1,95%	92,74%	89,38%
	feed-for. back.	t-t-t-p	4	4	3,52%	3,37%	1,97%	1,93%	92,84%	89,47%

Çizelge 5.15. H_{ort} parametresi ANN modelleme sonuçları

Model	Operations		Errors of Models				Correlations			
	Network Type	Trans. Funct.	# of L	# of N	RMSE of TRA	RMSE of TEST	MAE of TRA	MAE of TEST	Corr. Tra	Corr. Test
H1	feed-for. back.	t-p	2	2	3,31%	3,09%	1,85%	1,74%	93,03%	90,11%
T1	cascade-for. back.	t-t-p	3	3	3,33%	3,09%	1,83%	1,73%	92,97%	90,07%
H1	feed-for. back.	l-p	2	2	3,35%	3,11%	1,87%	1,76%	92,89%	89,90%
T2	feed-for. back.	t-t-t-p	4	4	3,31%	3,12%	1,89%	1,78%	93,04%	89,99%
H2	cascade-for. back.	t-p	2	2	3,19%	3,06%	1,76%	1,70%	93,53%	90,31%
	cascade-for. back.	t-t-t	3	3	3,21%	3,09%	1,78%	1,74%	94,41%	90,08%
H2	feed-for. back.	t-p	2	2	3,21%	3,09%	1,79%	1,73%	93,45%	90,10%
T1	feed-for. back.	t-t-t-p	4	2	3,20%	3,11%	1,79%	1,75%	93,47%	90,01%
H3	feed-for. back.	t-p	2	2	3,22%	3,10%	1,80%	1,74%	93,43%	90,10%
	cascade-for. back.	t-t-p	3	3	3,22%	3,10%	1,78%	1,72%	93,42%	90,10%
H3	cascade-for. back.	l-l-t-l-p	5	5	3,23%	3,09%	1,81%	1,74%	93,37%	90,13%
T1	feed-for. back.	l-l-p	3	3	3,24%	3,10%	1,81%	1,74%	93,33%	90,12%
H5	feed-for. back.	t-p	2	2	3,21%	3,10%	1,81%	1,75%	93,44%	90,07%
	feed-for. back.	t-t-t-p	4	4	3,19%	3,07%	1,76%	1,71%	94,66%	92,87%

Çizelge 5.16. H_{max} parametresi ANN modelleme sonuçları

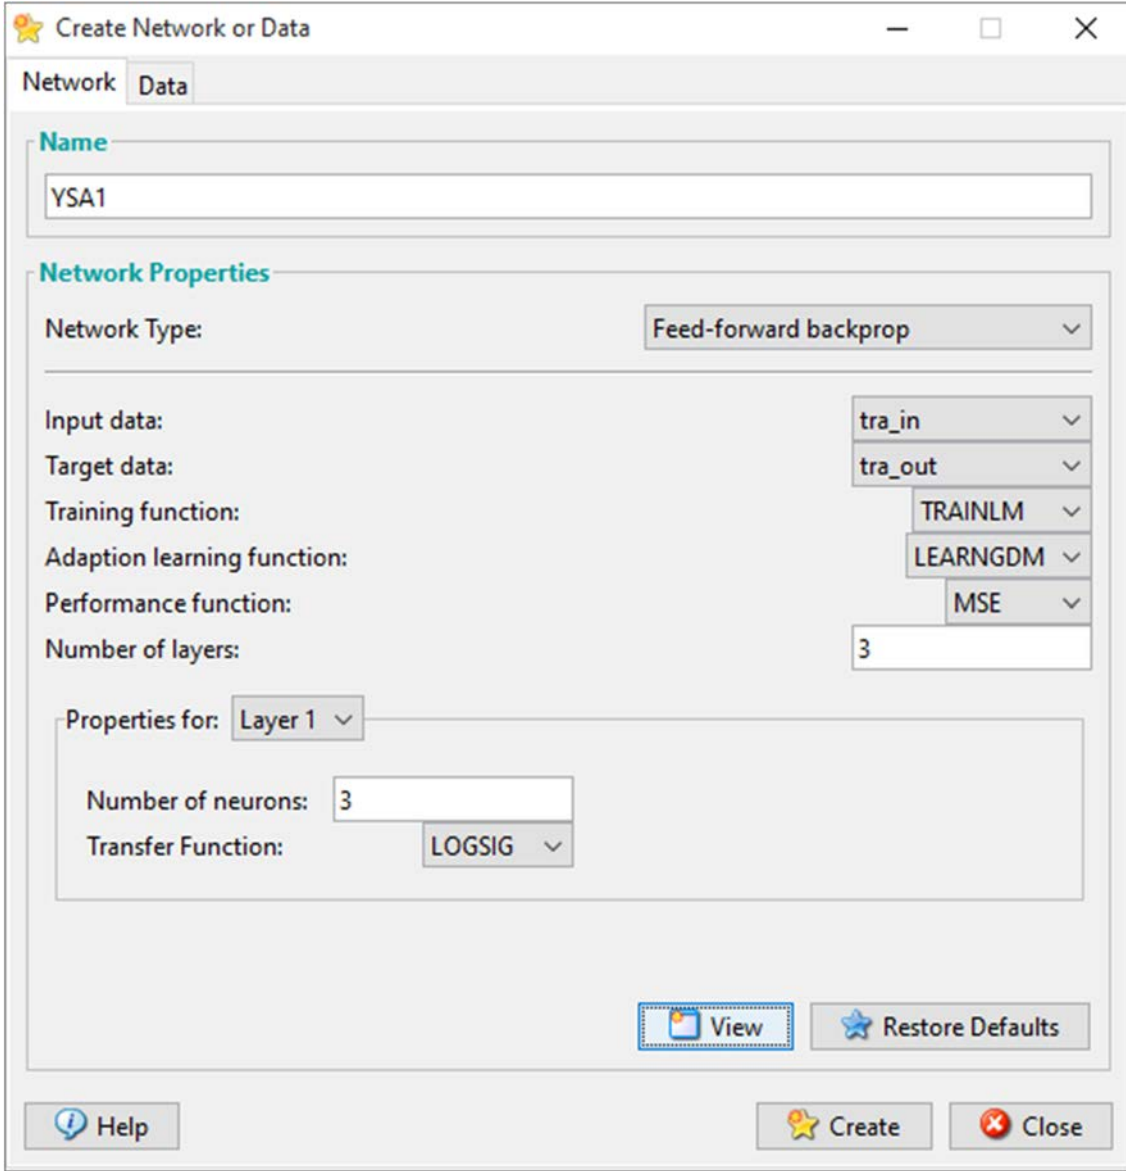
Model	Operations				Errors of Models				Correlations	
	Network Type	Trans Funct.	# of L	# of N	RMSE of TRA	RMSE of TEST	MAE of TRA	MAE of TEST	Corr. Tra	Corr. Test
H1	feed-for. back.	t-p	2	2	4,56%	4,52%	2,59%	2,56%	88,89%	83,25%
T1	cascade-for. back.	t-t-p	3	3	4,48%	4,30%	2,53%	2,52%	89,36%	84,76%
H1	feed-for. back.	l-p	2	2	4,58%	4,57%	2,59%	2,56%	88,87%	82,97%
T2	feed-for. back.	t-t-t-p	4	4	4,45%	4,37%	2,54%	2,50%	89,47%	84,24%
H2	cascade-for. back.	t-p	2	2	4,51%	4,46%	2,55%	2,53%	89,20%	83,58%
	cascade-for. back.	t-t-t	3	3	4,55%	4,53%	2,62%	2,58%	89,32%	83,21%
H2	feed-for. back.	t-p	2	2	4,53%	4,43%	2,56%	2,54%	89,11%	83,82%
T1	feed-for. back.	t-t-t-p	4	2	4,52%	4,50%	2,56%	2,56%	89,13%	83,39%
H3	feed-for. back.	t-p	2	2	4,54%	4,51%	2,57%	2,57%	89,07%	83,38%
	cascade-for. back.	t-t-p	3	3	4,53%	4,52%	2,55%	2,57%	89,13%	83,29%
H3	cascade-for. back.	l-l-t-l-p	5	5	4,45%	4,43%	2,55%	2,54%	89,51%	83,86%
T1	feed-for. back.	l-l-p	3	3	4,52%	4,47%	2,56%	2,56%	89,14%	83,60%
H5	feed-for. back.	t-p	2	2	4,58%	4,56%	2,58%	2,56%	88,87%	82,93%
	feed-for. back.	t-t-t-p	4	4	4,48%	4,49%	2,55%	2,57%	89,36%	83,49%

Çizelge 5.13, 5.14, 5.15 ve 5.16'da görüldüğü üzere dalga parametrelerini modelleme aşamaları ve sonuçları verilmiştir. Kullanılan transfer fonksiyonları kısaltmalar halinde gösterilmiştir: $t = \text{tanjant-sigmoid}$, $l = \text{logaritmik-sigmoid}$, $p = \text{purelin (lineer)}$ fonksiyonlarını belirtmektedir.


Her parametre kendi içerisindeki model tipleri ile kıyaslandığında sonuçlar arasında büyük farklar olmadığı görülmektedir. En tutarlı modellerin seçiminde kıyaslama ölçütü olarak sadece bu çizelgelerde görülen değerler kullanılmamış, gerçek değerler ile tahmin değerlerinin saçılma grafikleri de etkili olmuştur.

5.2.1. H_s parametresi

Ölçütler karşılaştırıldığında H_s parametresi için en tutarlı model “Model-6” yani “H3T1” olarak seçilmiştir. Eğitimde ileri beslemeli geri yayınlı ağ yapısı kullanılmıştır. Öğrenme algoritması olarak ise Lavenberg-Marquardt kullanılarak ağı öğrenme oranı tespit edilmiştir. Toplamda 3 katman ve ara katmanlardaki nöron sayısı 3 seçilmiştir. Transfer fonksiyonu olarak ise Logaritmik-Sigmoid fonksiyonu kullanılmıştır (Şekil 5.25, Şekil 5.26).




Şekil 5.25. H_s parametresi Matlab ortamında oluşturulan ANN tabanı




Şekil 5.26. H_s parametresi ANN mimari yapısı


Eğitim için epok 100 seçilmiştir ve ağırlık değerleri her eğitimden sonra yenilenecek performansın en iyi olduğu nokta bulunmaya çalışılmıştır (Şekil 5.27). Verilerin girişi sırasında tüm değerlerin 0 ile 1 arasında olması için değerler normalize edilmiştir.



Şekil 5.27. H_s parametresi ANN eğitim grafiği



Şekil 5.28. ANN modeli H_s parametresi eğitim aşaması


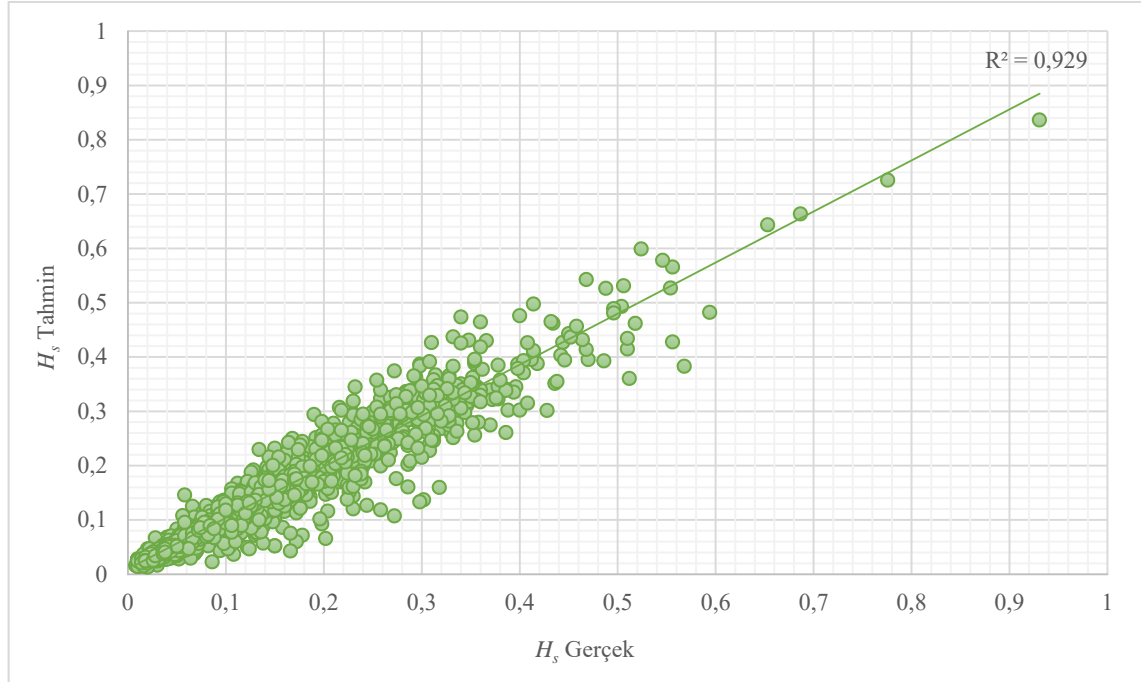


Şekil 5.29. ANN modeli H_s parametresi test aşaması

Şekil 5.28 ve 5.29'da yapay sinir ağları modellemesinde H3T1 modeli için eğitim ve test aşamasındaki program çıktıları yani tahmin verileri verilmiştir. Mavi değerler gerçek verileri, pembe değerler ise modelin tahmin verilerini temsil etmektedir. Şekillerde görüleceği üzere model gerçek verilere oldukça yakın değerler vermektedir. Bu aşamalarda 2 ayrı yöntem ile hesaplanan hata değerleri ise Çizelge 5.17'de verilmiştir.

Çizelge 5.17. H_s parametresi eğitim ve test aşaması hata oranları

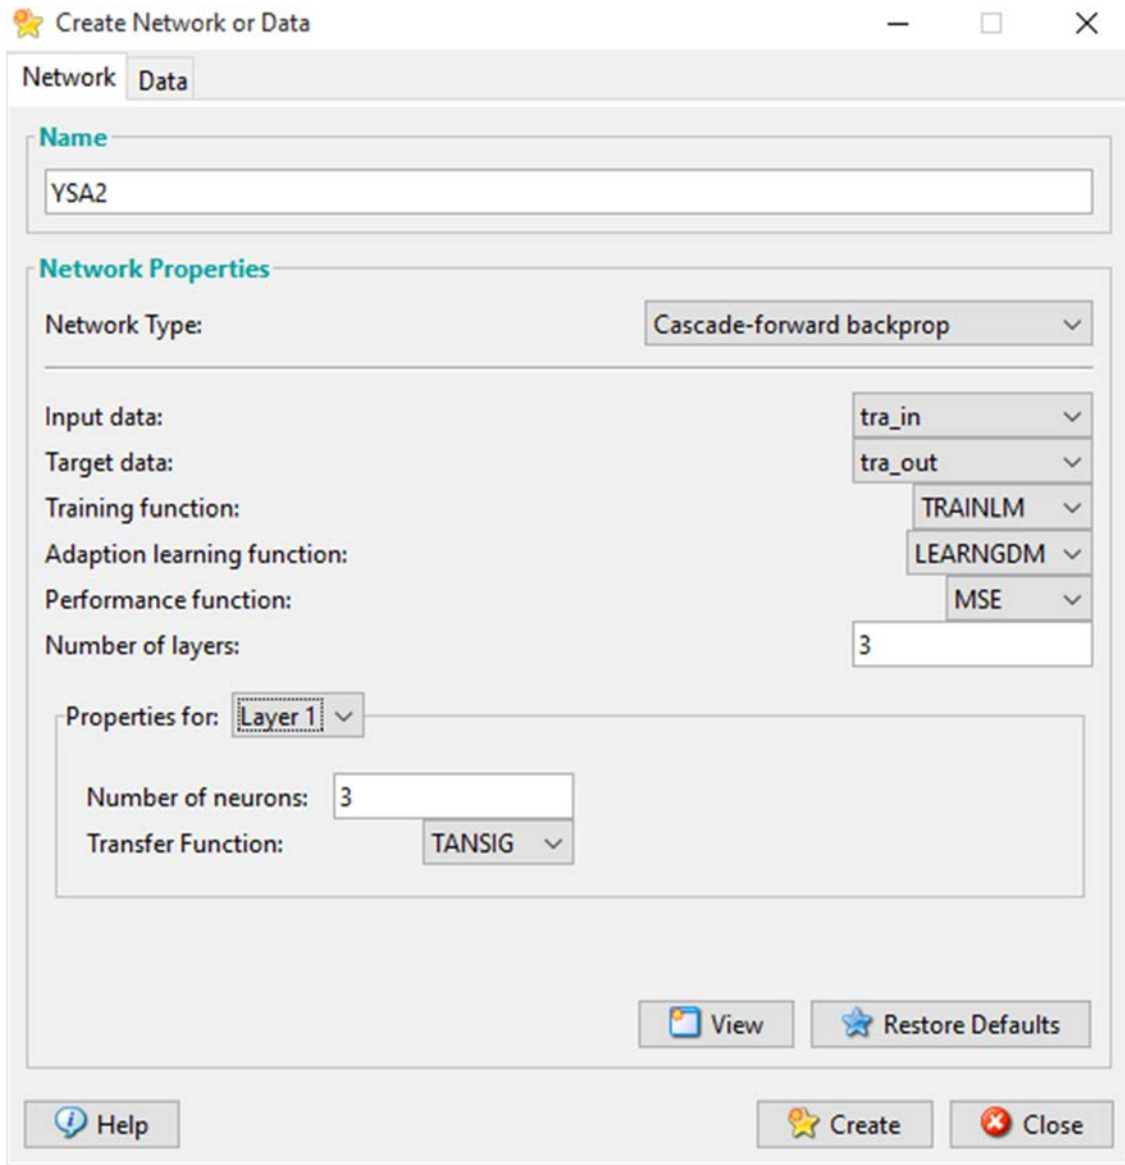
Model	HATA PARAMETRELERİ			
	Mutlak Hata		RMSE	
H3T1	Eğitim	Test	Eğitim	Test
	% 1.82	% 1.90	% 3.33	% 3.16

Şekil 5.30. H_s parametresi (ANN) eğitim aşaması saçılma diyagramı ve R^2 değeriŞekil 5.31. H_s parametresi (ANN) test aşaması saçılma diyagramı ve R^2 değeri


Şekil 5.30 ve 5.31’de görüldüğü üzere gerçek veriler ve tahmin verileri arasındaki ilişki verilmiştir. Kullanılan model için eğitim aşamasında $R^2=0.95$, test aşamasında ise $R^2=0.93$ bulunmuştur.

5.2.2. $H_{1/10}$ parametresi

Ölçütler karşılaştırıldığında $H_{1/10}$ parametresi için en tutarlı model “Model-3” yani “H2” olarak seçilmiştir. Eğitimde “Cascade” ileri beslemeli geri yayımlı ağ yapısı kullanılmıştır. Bu ağ yapısının standart ileri beslemeli ağ yapısı ile farkı giriş parametreleri ile her katmanda bir bağlantı oluşturmasıdır. Öğrenme algoritması olarak ise Lavenberg-Marquardt kullanılarak ağın öğrenme oranı tespit edilmiştir. Toplamda 3 katman ve ara katmanlardaki nöron sayısı 3 seçilmiştir. Transfer fonksiyonu olarak ise Tanjant-Sigmoid fonksiyonu kullanılmıştır (Şekil 5.32, Şekil 5.33).




Şekil 5.32. $H_{1/10}$ parametresi Matlab ortamında oluşturulan ANN tabanı




Şekil 5.33. $H_{1/10}$ parametresi ANN mimari yapısı


Eğitim için epok 100 seçilmiştir ve ağırlık değerleri her eğitimden sonra yenilenerek performansın en iyi olduğu nokta bulunmaya çalışılmıştır (Şekil 5.34). Verilerin girişi sırasında tüm değerlerin 0 ile 1 arasında olması için değerler normalize edilmiştir.



Şekil 5.34. $H_{1/10}$ parametresi ANN eğitim grafiği



Şekil 5.35. ANN modeli $H_{1/10}$ parametresi eğitim aşaması





Şekil 5.36. ANN modeli $H_{1/10}$ parametresi test aşaması

Şekil 5.35 ve 5.36'da yapay sinir ağı modellemesinde H2 modeli için eğitim ve test aşamasındaki program çıktıları yani tahmin verileri verilmiştir. **Mavi** değerler gerçek verileri, **pembe** değerler ise modelin tahmin verilerini temsil etmektedir. Bu aşamalarda 2 ayrı yöntem ile hesaplanan hata değerleri ise Çizelge 5.18'de verilmiştir.

Çizelge 5.18. $H_{1/10}$ parametresi eğitim ve test aşaması hata oranları

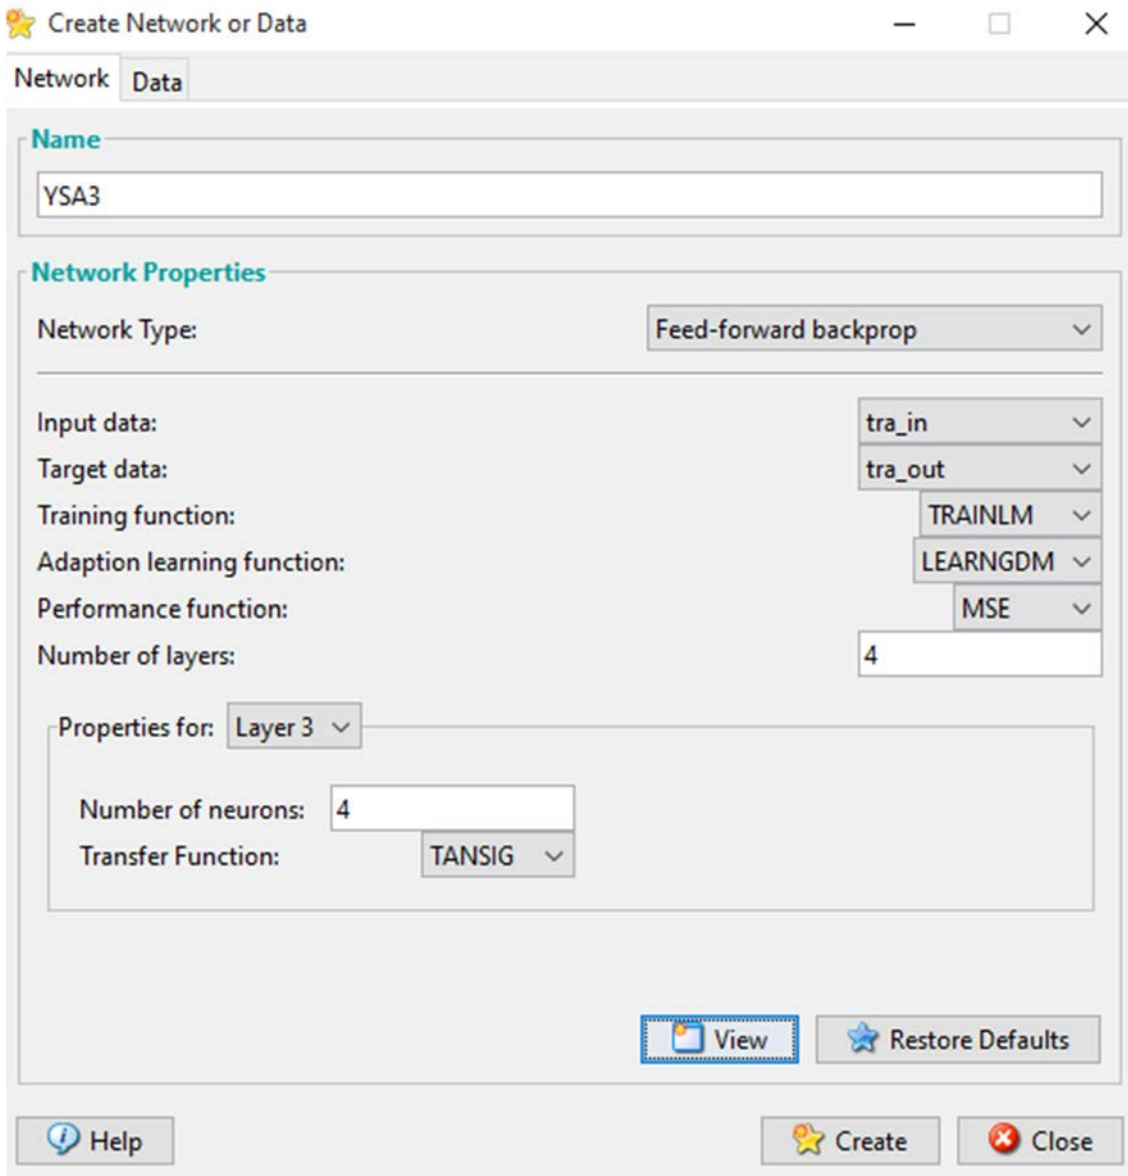
Model	HATA PARAMETRELERİ			
	Mutlak Hata		RMSE	
H2	Eğitim	Test	Eğitim	Test
	% 1.98	% 1.92	% 3.52	% 3.34

Şekil 5.37. $H_{1/10}$ parametresi (ANN) eğitim aşaması saçılma diyagramı ve R^2 değeriŞekil 5.38. $H_{1/10}$ parametresi (ANN) test aşaması saçılma diyagramı ve R^2 değeri


Şekil 5.37 ve 5.38’de görüldüğü üzere gerçek veriler ve tahmin verileri arasındaki ilişki verilmiştir. Kullanılan model için eğitim aşamasında $R^2=0.95$, test aşamasında ise $R^2=0.93$ bulunmuştur.

5.2.3. H_{ort} parametresi

Ölçütler karşılaştırıldığında H_{ort} parametresi için en tutarlı model “Model-7” yani “H5” olarak seçilmiştir. Eğitimde ileri beslemeli geri yayınlı ağ yapısı kullanılmıştır. Öğrenme algoritması olarak ise Lavenberg-Marquardt kullanılarak ağı öğrenme oranı tespit edilmiştir. Toplamda 4 katman ve ara katmanlardaki nöron sayısı 4 seçilmiştir. Transfer fonksiyonu olarak ise Tanjant-Sigmoid fonksiyonu kullanılmıştır (Şekil 5.39, Şekil 5.40).




Şekil 5.39. H_{ort} parametresi Matlab ortamında oluşturulan ANN tabanı




Şekil 5.40. H_{ort} parametresi ANN mimari yapısı


Eğitim için epok 100 seçilmiştir ve ağırlık değerleri her eğitimden sonra yenilenerek performansın en iyi olduğu nokta bulunmaya çalışılmıştır (Şekil 5.41). Verilerin girişi sırasında tüm değerlerin 0 ile 1 arasında olması için değerler normalize edilmiştir.



Şekil 5.41. H_{ort} parametresi ANN eğitim grafiği



Şekil 5.42. ANN modeli H_{ort} parametresi eğitim aşaması





Şekil 5.43. ANN modeli H_{ort} parametresi test aşaması

Şekil 5.42 ve 5.43'te yapay sinir ağları modellemesinde H2 modeli için eğitim ve test aşamasındaki program çıktıları yani tahmin verileri verilmiştir. **Mavi** değerler gerçek verileri, **pembe** değerler ise modelin tahmin verilerini temsil etmektedir. Bu aşamalarda 2 ayrı yöntem ile hesaplanan hata değerleri ise Çizelge 5.19'da verilmiştir.

Çizelge 5.19. H_{ort} parametresi eğitim ve test aşaması hata oranları

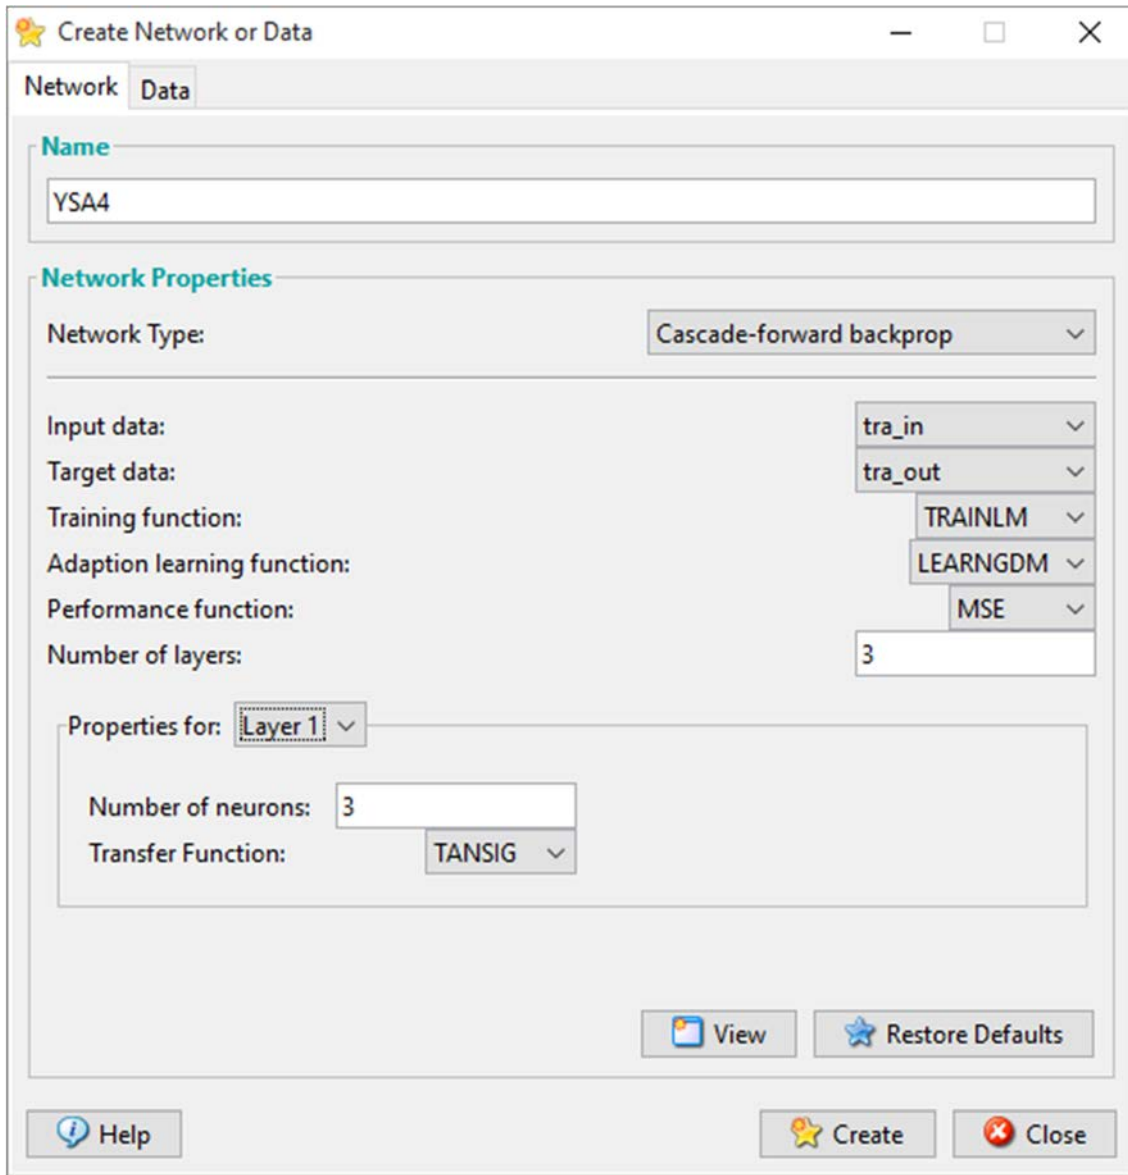
Model	HATA PARAMETRELERİ			
	Mutlak Hata		RMSE	
H5	Eğitim	Test	Eğitim	Test
	% 1.76	% 1.71	% 3.19	% 3.07

Şekil 5.44. H_{ort} parametresi (ANN) eğitim aşaması saçılma diyagramı ve R^2 değeriŞekil 5.45. H_{ort} parametresi (ANN) test aşaması saçılma diyagramı ve R^2 değeri


Şekil 5.44 ve 5.45’te görüldüğü üzere gerçek veriler ve tahmin verileri arasındaki ilişki verilmiştir. Kullanılan model için eğitim aşamasında $R^2=0.95$, test aşamasında ise $R^2=0.93$ bulunmuştur.

5.2.4. H_{max} parametresi

Ölçütler karşılaştırıldığında H_{max} parametresi için en tutarlı model “Model-1” yani “H1T1” olarak seçilmiştir. Eğitimde “Cascade” ileri beslemeli geri yayınlı ağ yapısı kullanılmıştır. Öğrenme algoritması olarak ise Lavenberg-Marquardt kullanılarak ağın öğrenme oranı tespit edilmiştir. Toplamda 3 katman ve ara katmanlardaki nöron sayısı 3 seçilmiştir. Transfer fonksiyonu olarak ise Tanjant-Sigmoid fonksiyonu kullanılmıştır (Şekil 5.46, Şekil 5.47).




Şekil 5.46. H_{max} parametresi matlab ortamında oluşturulan ANN tabanı




Şekil 5.47. H_{max} parametresi ANN mimari yapısı


Eğitim için epok 100 seçilmiştir ve ağırlık değerleri her eğitimden sonra yenilenerek performansın en iyi olduğu nokta bulunmaya çalışılmıştır (Şekil 5.48). Verilerin girişi sırasında tüm değerlerin 0 ile 1 arasında olması için değerler normalize edilmiştir.



Şekil 5.48. H_{max} parametresi ANN eğitim grafiği



Şekil 5.49. ANN modeli H_{max} parametresi eğitim aşaması





Şekil 5.50. ANN modeli H_{max} parametresi test aşaması

Şekil 5.49 ve 5.50’de yapay sinir ağları modellenmesinde H1T1 modeli için eğitim ve test aşamasındaki program çıktıları yani tahmin verileri verilmiştir. **Mavi** değerler gerçek verileri, **pembe** değerler ise modelin tahmin verilerini temsil etmektedir. Bu aşamalarda 2 ayrı yöntem ile hesaplanan hata değerleri ise Çizelge 5.20’de verilmiştir.

Çizelge 5.20. H_{max} parametresi eğitim ve test aşaması hata oranları

Model	HATA PARAMETRELERİ			
	Mutlak Hata		RMSE	
H1T1	Eğitim	Test	Eğitim	Test
	% 2.53	% 2.52	% 4.48	% 4.30

Şekil 5.51. H_{max} parametresi (ANN) eğitim aşaması saçılma diyagramı ve R^2 değeriŞekil 5.52. H_{max} parametresi (ANN) test aşaması saçılma diyagramı ve R^2 değeri

Şekil 5.51 ve 5.52’de görüldüğü üzere gerçek veriler ve tahmin verileri arasındaki ilişki verilmiştir. Kullanılan model için eğitim aşamasında $R^2=0.91$, test aşamasında ise $R^2=0.87$ bulunmuştur.

6. TARTIŞMA VE SONUÇ

Yapı maliyeti yüksek ve ekonomik yaşam ömürleri uzun kıyı yapılarının projelendirilmesinde en önemli adımlardan birisi *dalga yüksekliği parametresinin* doğru belirlenmesidir. Kıyı yapılarını gerek statik, gerekse dinamik açıdan zorlayan bu parametre birçok durumda ya yetersiz ya da eksik olarak veri setleri ile belirlenmektedir. Özellikle H ve T verilerindeki eksiklikler projelendirme aşamasında hatalara sebep olmaktadır. Dalga parametrelerinin doğru olarak belirlenebilmesi yüksek maliyetli kıyı yapılarının yatırım ve onarım maliyetlerini düşürmektedir.

Çizelge 6.1. Çalışmada kabul edilen yapay zeka metotları, model ve sonuçları


Mthd.	Prmtr.	Model	RMSE of TRA	RMSE of TEST	MAE of TRA	MAE of TEST	Cor. of TRA	Cor. of TEST
A N F I S	H_s	H3T1	3.15	3.15	1.79	1.80	0.95	0.94
	$H_{1/10}$	H5	3.35	3.42	1.92	1.94	0.95	0.93
	H_{ort}	H5	2.95	3.45	1.65	1.73	0.96	0.94
	H_{max}	H5	3.94	4.28	2.50	2.47	0.93	0.89
A N N	H_s	H3T1	3.33	3.16	1.82	1.90	0.95	0.93
	$H_{1/10}$	H2	3.52	3.34	1.98	1.92	0.95	0.93
	H_{ort}	H5	3.19	3.07	1.76	1.71	0.95	0.93
	H_{max}	H1T1	4.48	4.30	2.53	2.52	0.91	0.87

Çizelge 6.1’de bu tez çalışması sonucunda her bir parametre için kullanılan yapay zeka metotları ve kabul edilen modeller, hata oranları ve korelasyon katsayıları verilmiştir.


Çalışma kapsamında Filyos Bölgesinde 1995-1996 yıllarında periyodu 2 saat olarak ölçülmüş yaklaşık 8000 adet veri kullanılmıştır. Bu veriler ile sadece “ H ” veya “ H ve T ” kombinasyonu kullanılarak tahmin modelleri oluşturulmuştur. Çalışma da yapay zeka teknikleri kullanılmıştır: ANN ve ANFIS. Kullanılan bulanık sinir ağı metodu ANFIS (Uyarlamalı Ağ Temelli Bulanık Çıkarım Sistemi) dir. Bu metot yapay sinir ağları ile bulanık mantığın bir arada kullanılmasını sağlamakla beraber içerdiği iki yapay zekâ tekniği birbirlerinin dezavantajlarını gidermektedir. Yapay sinir ağları modellemesinde oluşturulan modeller ağ yapıları, öğrenme algoritmaları, katman sayıları ve nöron sayıları ile birçok deneme ile belirlenmiştir. Bu denemeler arasında en iyi sonuçları veren model ve parametreleri seçilmiştir. Aynı şekilde ANFIS için de bu modeller dilsel terim sayısı, eğitim fonksiyonları, eğitim metotları ile birçok denemeye tabi tutulmuş ve en verimli sonuçları veren model ve parametreler seçilmiştir.

Bu iki metotla yapılan çalışmalar istatistikî analizlere tabi tutulmuştur. Modellerin tahmin etmiş olduğu değerlere ilişkin hata sonuçları “RMSE” ve “MAE” metotları ile hesaplanmış ve sonuçlar verilmiştir. Ayrıca modellerin tahmin ettiği değerler gerçek değerler ile saçılma diyagramına aktarılmış ve aralarındaki ilişki korelasyon katsayısı ile


belirlenmiştir. Bu değerlerin grafiksel karşılaştırması Şekil 6.1, 6.2, 6.3 ve 6.4'te verilmiştir.




Şekil 6.1. ANFIS ve ANN, RMSE eğitim değerleri grafiksel gösterimi



Şekil 6.2. ANFIS ve ANN, RMSE test değerleri grafiksel gösterimi



Şekil 6.3. ANFIS ve ANN, MAE eğitim değerleri grafiksel gösterimi




Şekil 6.4. ANFIS ve ANN, MAE test değerleri grafiksel gösterimi

ANFIS metodunda öne çıkan öğrenme fonksiyonları “Gumbell ve Gauss” olmuştur. Operasyon metodu olarak “hibrit” metodu sağlıklı sonuçlar sağlamaktadır. Üyelik fonksiyonu sayısına baktığımızda ise çok düşük rakamların daha hızlı öğrendiğini fakat yanılma oranının daha fazladır. Bunun yanında üyelik fonksiyonu sayısını çok artırmak hem öğrenmeyi yavaşlatmakta hem de eğitim aşamasında düzgün sonuçlar alınsa bile test aşamasında anlamsız sonuçlar vermektedir. Bu da programın eğitim aşamasında ezberlemeye zorlandığını göstermektedir.


ANN metodunda ‘‘Sigmoid’’ fonksiyonlar ön plana çıkmaktadır. Öğrenme algoritmasında ise Levenberg Marquardt metodu hızlı öğrenme ve iyi yakınsayabilme özelliği ile tercih sebebi olmuştur. İleri beslemeli geri yayınlı ağ yapıları dalga parametreleri modellenmesinde iyi uyum sağlamıştır.

Her parametreye kendi içerisinde bakacak olursak, hem ANFIS hem de ANN metodu istatistiki verilerde aşağı yukarı aynı sonuçları vermektedir. Ayrıca her iki metotta da ‘‘eğrisel fonksiyonlar’’ın dalga parametrelerinin modellenmesi aşamalarında daha etkin olduğu söylenebilir. İstatistiki sonuçlar karşılaştırıldığında kullanılan yöntemlere en çok uyum sağlayan parametrenin H_s olduğu görülmüştür. Modellemesi gerçekleştirilen parametreler içerisinde modellemeyi en çok zorlaştıran parametre ise H_{max} olmuştur. Çünkü H_{max} parametresi dalga yüksekliğinin en fazla olduğu noktadır ve bu uç noktalar bir rastgelelik içerisinde olduklarından tahmini oldukça karmaşık ve zordur.

Analizler sonucunda her iki metodunda tutarlı ve yeterli sonuçlar verdiği saptanmıştır. Fakat bulanık mantık ve yapay sinir ağlarının birlikte kullanıldığı ve birbirlerinin dezavantajlarını ortadan kaldıran ANFIS metodu ANN’ye göre daha tutarlı, daha düşük hata oranlı ve daha yüksek korelasyonlu tahminler gerçekleştirmiştir (Şekil 6.5 ve 6.6). Her parametre kendi içerisinde uç noktalar barındırmaktadır, bu uç noktalardaki verilerin az miktarda olmasından dolayı bu kısımlarda programın öğrenmesi daha zordur. ANFIS metodu ile gerçekleştirilen modellemelerde her parametre için uç noktalarda dahi tahmin oranlarının yüksek olduğu görülmekte, ANN metodu ile gerçekleştirilen modellemelerde ise bu uç noktalara çok daha az ulaşılabildiği görülmektedir.



Şekil 6.5. ANFIS ve ANN, CORR. eğitim değerleri grafiksel gösterimi



Şekil 6.6. ANFIS ve ANN, CORR. test değerleri grafiksel gösterimi

Sonuç olarak; kıyı yapılarının projelendirilmesinde, eksik dalga verilerinin tamamlanmasında, ileriye yönelik dalga yüksekliği tahmin edilmesinde yapay zeka tekniklerinin kullanılması daha doğru ve tutarlı sonuçların elde edilmesini sağlamaktadır. Bu çalışmada, diğer yapay zekâ teknikleri ile kıyaslandığında ANFIS metodunun daha tutarlı sonuçlar verdiği sonucuna varılmıştır. Bu denli maliyetli yapıların projelendirilmesinde ana faktör olan dalga yüksekliğinin doğru belirlenmesi hem yapım maliyeti hem de işletme ve onarım maliyetleri açısından büyük avantajlar sağlayacaktır.

7. KAYNAKLAR

- AGRAWAL, J.D. and DEO, M.C. 2002. On-line Wave Prediction. *Marine Structures*, 15 (1): 57-74.
- AKPINAR, A., ÖZGER, M. and KÖMÜRÇÜ, M.İ. 2014. Prediction of wave parameters by using fuzzy inference system and parametric models along the south coasts of the Black Sea. *Journal of Marine Science and Technology*, 19: 1-14.
- ALTUNKAYNAK, A. and WANG, K.-H. 2012. Estimation of significant wave height in shallow lakes using the expert system techniques. *Expert Systems with Applications*, 39: 2549-2559.
- BALAS, C.E., KOÇ, L., BALAS, L. 2004. Predictions of missing wave data by recurrent neurons. *Journal of Waterway Port Coastal and Ocean Engineering-ASCE*, 130 (5): 256-265.
- BALAS, C.E. ve TÜR, R. 2006. Mersin Limanı Yükleme Boşaltma Kapasitesinin Bulanık Mantık Yaklaşımı ile Modellenmesi. Türkiye'nin Kıyı ve Deniz Alanları VI. Ulusal Konferansı, Türkiye Kıyıları 06 Konferansı Bildiriler Kitabı, ss. 681-690, 7-11 Kasım, Muğla
- BLACK, M. 1937. Vagueness: An exercise in logical analysis. *Philosophy of Science*, 4: 427-455. (Reprinted in R. Keefe, P. Smith (eds.): *Vagueness: A Reader*, MIT Press 1997)
- CANGIR, B. 2008. Hurma ve Sarısu (Antalya) Bölgelerindeki Zeminlerin Geoteknik Özelliklerinin Araştırılması. Yüksek lisans tezi, T.C. Akdeniz Üniversitesi, Antalya.
- CHAKRABARTI, S.K. 1987. Hydrodynamics of Offshore Structures. Computational Mechanics Publications, pp. 128-165, Southampton, Boston.
- CLEMENT, S.J. 1998. Optimising Fuzzy Logic Traffic Signal Control Systems. Proceedings of the 22nd Australian Transport Research Forum, pp. 897-912, Sydney.
- DEKA, P.C. and PRAHLADA, R. 2012. Discrete wavelet neural network approach in significant wave height forecasting for multistep lead time. *Ocean Engineering*, 43: 32-42.
- DEO, M.C. and NAIDU, C.S. 1999. Real Time Wave Forecasting using Neural Networks. *Ocean Engineering*, 26 (3): 191-203.
- DIXIT, P., LONDHE S. and DANDAWATE, Y. 2015. Removing prediction lag in wave height forecasting using Neuro-Wavelet modeling technique. *Ocean Engineering*, 93: 74-83.

- ELMAS, Ç. 2007. Yapay Zeka Uygulamaları. Seçkin Yayıncılık, Ankara.
- ELMAS, Ç. 2003. Bulanık Mantık Denetleyiciler. Seçkin Yayıncılık, Ankara.
- ELMDOUST, A. and KERACHIAN, R. 2012. Wave height prediction using the rough set theory. *Ocean Engineering*, 54: 244-250.
- FİLYOS, 2015. Filyos bölgesi tanıtım. [Son erişim tarihi: 20.10.2015]
www.filyosum.com
- GAUR, S. and DEO, M.C. 2008. Real-time wave forecasting using genetic programming. *Ocean Engineering*, 35: 1166-1172.
- GÜNAYDIN, K. 2008, The estimation of monthly mean significant wave heights by using artificial neural network and regression methods. *Ocean Engineering*, 35: 1406-1415.
- HADADPOUR, S., ETEMAD-SHAHIDI, A. and KAMRANZAD, B. 2014. Wave energy forecasting using artificial neural networks in the Caspian Sea. *Institution of Civil Engineers*, 167 (MA1): 42-52.
- HARVEY, R.L. 1994. Neural network principles. Prentice-Hall Inc., p. 197, New Jersey.
- HAYKIN, S. 1994. Neural Networks: A Comprehensive Foundation. Prentise Hall PTR Upper Saddle River, NJ, USA.
- HEBB, D.O. 1949. The Organization of Behavior. New York: Wiley & Sons
- HINES, J.W. 1997. Fuzzy and Neural Approaches in Engineering: MATLAB Supplement, John Wiley and Sons, p. 244, New York.
- HOFFMAN, D. and WALDEN, D.A. 1977. Environmental Wave Data for Determining Hull Structural Loadings. Ship Structure Committee, U.S. Coast Guard Headquarters, Report SSC-268, Washington, D.C.
- HOGBEN, N. and LUMB, F.E. 1967. Ocean Wave Statistics, HMSO, London.
- HOLLAND, J.H. 1975. Adaption in Natural and Artificial Systems. University of Michigan Pres, Ann Arbor, MI
- HOPFIELD, J. and TANK, D.W. 1986. Computing with Neural Circuits: A Model. *Science*, New Series, 233 (4764): 625-633.
- HUANG, M.-C. 2004. Wave parameters and functions in wavelet analysis. *Ocean Engineering*, 31: 111-125.
- JACOB, C. 2003. Fuzzy Systems in Knowledge Engineering. Artificial Intelligence Course Notes, Chapter 4.

- KABDAŞLI, S. 1992 Kıyı Mühendisliği. İTÜ İnşaat Fakültesi Matbaası, İstanbul
- KAMRANZAD, B., ETEMAD-SHAHIDI, A. and KAZEMINEZHAD, M.H. 2011. Wave height forecasting in Dayyer, the Persian Gulf. *Ocean Engineering*, 38: 248-255.
- KALAGIROU, S.A. 1999. Applications of neural networks in energy systems. *Energy Conversion and Management*, 40: 1073-1087
- KARAKUZU, C. 2006. Bulanık Modelleme ve Akıllı Denetim. Fen Bilimleri Enstitüsü, Kocaeli Üniversitesi, Kocaeli.
- KÜÇÜK, B. ve AYVAZ, B. 2013. Yapay Zeka Teknikleri. Lisans tezi, T.C. Akdeniz Üniversitesi, Antalya.
- LENAT, D. and FEİGENBAUM, E. 1991. Artificial Intelligence. On the Thresholds of Knowledge, pp. 47
- LONDHE, S.N. 2008. Soft computing approach for real-time estimation of missing wave heights. *Ocean Engineering*, 35: 1080-1089.
- LONDHE, S.N. and PANCHANG, V. 2007. Correlation of wave data from buoy networks. *Estuarine Coastal and Shelf Science*, 74: 481-492.
- ŁUKASIEWICZ, J. 1920. O logice trójwartościowej (in Polish). *Ruch filozoficzny*, 5: 170–171.
- MAKARYNSKYY, O. 2004. Improving wave predictions with artificial neural networks. *Ocean Engineering*, 31: 709-724.
- MAKARYNSKYY, O., PİRES-SILVA, A.A., MAKARYNSKA, D. and VENTURA-SOARES, C. 2005. Artificial Neural Networks in Wave Predictions at the West Coast of Portugal. *Computer and Geosciences*, 31 (4): 415-424.
- MALEKMOHAMADI, I., BAZARGAN-LARI, M.R., KERACHIAN, R., NIKOO, M.R. and FALLAHNIA, M. 2011. Evaluating the efficacy of SVMs, BNs, ANNs and ANFIS in wave height prediction. *Ocean Engineering*, 38: 487-497.
- MAMDANI, E.H. 1974. Application of fuzzy algorithms for control of simple dynamic plant. *Proceedings IEE*, 121: 1585-1588.
- MANDAL, S. and PRABAHARAN, N. 2006. Ocean Wave Forecasting using Recurrent Neural Networks. *Ocean Engineering*, 33 (10): 1401-1410.
- McCULLOCH, W.S. and PITTS, W.H. 1943. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, 5: 115-133.

- MINSKY M. and PAPERT, S. 1972 (2nd edition with corrections, first edition 1969). Perceptrons: An Introduction to Computational Geometry, The MIT Press, Cambridge MA.
- NAYAK, P.C. and SUDHEER, K.P. 2008. Fuzzy Identification Based on Cluster Estimation Reservoir Inflow Forecasting. *Processes*, 22 (X): 827-841.
- NITSURE, S.P., LONDHE, S.N. and KHARE, K.C. 2012. Wave forecasts using wind information and genetic programming. *Ocean Engineering*, 54: 61-69
- ÖZÇALIK, H.R. ve UYGUR, A.F. 2003. Dinamik Sistemlerin Uyumlu Sinirsel-Bulanık Ağ Yapısına Dayalı Etkin Modellenmesi. *KSÜ Fen ve Mühendislik Dergisi*, 6 (1): 36-46.
- ÖZGER, M. 2010. Significant wave height forecasting using wavelet fuzzy logic approach. *Ocean Engineering*, 16 (37): 1443–1451.
- ÖZGER, M. and ŞEN Z. 2007. Prediction of wave parameters by using fuzzy logic approach. *Ocean Engineering*, 34: 460-469.
- ROJAS, R. 1996. Neural Networks: A Systematic Introduction. Springer-Verlag, Berlin.
- RUMELHART, D.E., HINTON, G.E. and WILLIAMS, R.J. 1986. Learning Internal Representations by Error Propagation. The MIT Press, Volume 1: Foundations, pp. 318-362, Cambridge, MA.
- RUSSELL, B. 1901. Russell's paradox. [Son erişim tarihi: 16.11.2015]
http://en.wikipedia.org/wiki/Russell%27s_paradox.
- SAĞIROĞLU, Ş., BEŞDOK, E. ve ERLER, M. 2003. Mühendislikte Yapay Zeka Uygulamaları-I : Yapay Sinir Ağları, Ufuk Kitap-Kırtasiye Yayıncılık, Kayseri.
- SVERDRUP, H.U. and MUNK, W.H. 1947. Wind, sea and swell : Theory of relations for forecasting. U.S. Navy Hydrographic Office: 601, Washington, 60 pp.
- SVOZIL, D., KVASNICKA, V. and POSPICHAL, J. 1997. Introduction to Multilayer Feed Forward Neural Net. *Chemometrics and Intelligent Laboratory Systems*, 39: 43-62.
- ŞAKA, S. 1999. Bulanık Kontrol ve Uygulamaları. Yüksek lisans tezi, İstanbul Teknik Üniversitesi, İstanbul 103 s.
- TOPALOĞLU, V. 2007. Yapay Sinir Ağları ile Dalga Yüksekliği Tahmini, Yüksek lisans tezi, İstanbul Teknik Üniversitesi, İstanbul.
- TRIPPI, R. and LEE, J.K. 1996. Artificial Intelligence in Finance & Investing. Irwin Professional Publishing, USA.

- TSAI, C.-P., LIN, C. and SHEN, J.-N. 2002. Neural network for wave forecasting among multi-stations. *Ocean Engineering*, 29: 1683-1695.
- TSOUKALAS, L.H. and UHRIG, R.E. 1996. Fuzzy and Neural Approaches in Engineering. John Wiley & Sons, New York, USA.
- TÜR, R. 2009. Liman Kapasite Artışlarının Modellenmesi. Doktora tezi, Gazi Üniversitesi, Ankara
- TÜR, R. ve BALAS, C.E. 2010. Belirgin Dalga Yüksekliklerinin Neuro-Fuzzy Yaklaşımı ile Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 25 (3): 505-510.
- VEMURI, V. 1992. Tutorial on Artificial Neural Networks: Concepts and Control Applications. Computer Society Press of IEEE, Los Alamitos, California.
- VIMALA, J., LATHA, G. and VENKATESAN, R. 2014. Real Time wave forecasting using artificial neural network with varying input parameter. *Indian Journal of Geo-Marine Sciences*, 43 (1): 82-87.
- WANG, W. and DING, J. 2003. Wavelet Network Model and Application to the Prediction of Hydrology, *Nature and Science*, 1 (1): 67-71.
- YURTOĞLU, H. (2005), Yapay sinir ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği. Devlet Planlama Teşkilatı, 2683, Ankara.
- YÜKSEL, Y., ÇEVİK, E. ve ÇELİKOĞLU, Y. 1998. Kıyı ve Liman Mühendisliği, Alaz Ofset, Ankara.
- ZADEH, L.A. 1965. Fuzzy Sets. *Information and Control*, 8: 338-353.
- ZAHEDI, F. 1991. An Introduction to Neural Networks and a comparison with Artificial intelligence and expert systems. *Interfaces*, 21 (2): 25-38.
- ZAMANI, A., SOLOMATINE, D., AZIMIAN, A. and HEEMINK, A. 2008. Learning from data for wind-wave forecasting. *Ocean Engineering*, 35 (10): 953-962.
- ZANAGANEH, M., MOUSAVI, S.J. and SHAHIDI, A.F.E. 2009. A hybrid genetic algorithm-adaptive network-based fuzzy inference system in prediction of wave parameters. *Engineering Applications of Artificial Intelligence*, 22: 1194-1202.

ÖZGEÇMİŞ



Serbay YÖNTEM, 1991 yılında Antalya'da doğdu. İlköğretim, ortaöğretim ve lise öğrenimini Antalya'da tamamladı. 2009 yılında girdiği Akdeniz Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü'nden 2013 yılında 5. olarak mezun oldu. Hemen ardından 2013-Eylül'de Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı'nda Yüksek Lisans öğrenimine başladı. SAP2000, STA4-CAD, AUTOCAD ve MS OFFICE programlarını ileri düzeyde biliyor. 2014-Ağustos, 2015-Ağustos arasında Akışkan Mühendislik Ltd. Şti.'de İnşaat Mühendisi olarak çalıştı. Burada HES'ler ve sulama yapıları üzerine kendini geliştirdi. Lisans ve yüksek

lisans öğreniminde kıyı mühendisliği alanında yapay zeka tekniklerini kullanmayı ve geliştirmeyi konu edindi ve çalışmalarına devam etmektedir.