

**TAŞ DOLGU DALGAKIRANLARIN YAPAY SİNİR AĞLARI,
BULANIK MANTIK SİSTEMLERİ VE GENETİK ALGORİTMA İLE
ÖN TASARIMI VE GÜVENİRLİK ANALİZİ**

M. Levent KOÇ

725878

**DOKTORA TEZİ
(İNŞAAT MÜHENDİSLİĞİ)**


**T.C. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

EKİM 2002

ANKARA

M. Levent Koç tarafından hazırlanan TAŞ DOLGU DALGAKIRANLARIN YAPAY SİNİR AĞLARI, BULANIK MANTIK SİSTEMLERİ VE GENETİK ALGORİTMA İLE ÖN TASARIMI VE GÜVENİRLİK ANALİZİ adlı bu tezin Doktora tezi olarak uygun olduğunu onaylarım.



Doç. Dr. Can E. Balas
Tez Yöneticisi



Prof. Dr. A. Samet Arslan
Tez Yöneticisi

Bu çalışma, jürümüz tarafından İnşaat Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir.

Başkan : Prof. Dr. Ayşen Ergin

Üye : Prof. Dr. Yalçın Yüksel


Üye : Prof. Dr. Melih Yanmaz

Üye : Doç. Dr. Can E. Balas

Üye : Doç. Dr. Lale Balas



Bu tez, Gazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygundur.



İÇİNDEKİLER

	Sayfa
ÖZET.....	i
ABSTRACT.....	iii
TEŞEKKÜR.....	v
ÇİZELGELERİN LİSTESİ	vi
ŞEKİLLERİN LİSTESİ	ix
SİMGELER VE KISALTMALAR.....	xvi
1. GİRİŞ	1
2. LİTERATÜR TARAMASI.....	8
3. YAPAY ZEKA TEKNİKLERİ.....	11
3.1. Yapay Sinir Ağları	11
3.1.1. İleri beslemeli denetimli yapay sinir ağları	13
3.1.2. Geri beslemeli denetimli yapay sinir ağları	16
3.2. Bulanık Mantık	17
3.2.1. Bulanık mantık sistemleri	18
3.2.1.1. Bulanıklaştırma.....	19
3.2.1.2. Bulanık kural tabanı ve bulanık genelleme.....	20
3.2.1.3. Durulaştırma	22
3.2.2. Bulanık sinir ağları.....	23
3.3. Genetik Algoritma	26
3.3.1. Seçilim	27
3.3.2. Çaprazlama	28
3.3.3. Mutasyon.....	28

4. EKSİK DALGA ÖLÇÜMLERİNİN YAPAY SİNİR	
AĞLARI İLE TAHMİNİ	30
4.1. Stokastik Modeller ve Yapay sinir Ağları.....	31
4.2. Dalga Parametrelerinin Tahmini.....	33
5. TAŞ DOLGU DALGAKIRANLARIN YAPAY ZEKA	
TEKNİKLERİ İLE ÖN TASARIMI	65
5.1. Taş Dolgu Dalgakıranlarda Deterministik Tasarım	66
5.2. Taş Dolgu Dalgakıranlarda Yapay Sinir Ağları,	
Bulanık Sistemler ve Bulanık Sinir Ağları ile Tasarım	69
5.3. Taş Dolgu Dalgakıranlarda Genetik Algoritma ile	
Güvenirlilik Analizi	115
6. SONUÇ VE ÖNERİLER.....	130
KAYNAKLAR	139
EKLER	147
ÖZGEÇMİŞ.....	157

**TAŞ DOLGU DALGAKIRANLARIN YAPAY SİNİR AĞLARI, BULANIK
MANTIK SİSTEMLERİ VE GENETİK ALGORİTMA İLE ÖN TASARIMI
VE GÜVENİRLİK ANALİZİ**

(Doktora Tezi)

M. Levent KOÇ

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

Ekim 2002

ÖZET

Bu çalışmada, yapay zeka teknikleri, taş dolgu dalgakıranların ön tasarımı sırasında çeşitli aşamalarda uygulanmış ve elde edilen sonuçlar mevcut yöntemlerle karşılaştırılmıştır. İleri ve geri beslemeli yapay sinir ağları kullanılarak Alanya deniz yöresi için dalga parametrelerinin (aynı anda belirgin dalga yüksekliği, periyodu ve yönü) tahmini yapılmıştır. Elde edilen sonuçlar, dalga parametrelerinin tahmininde yapay sinir ağlarının stokastik modellere kıyasla yüksek tahmin yeteneği gösterdiğini ve geri beslemeli sinir ağlarının uzun aralıklı tahminler için daha uygun olduğunu ortaya koymuştur. İleri beslemeli denetimli sinir ağları, bulanık sistemler ve bulanık sinir ağları ile genetik algoritmadan oluşan yapay zeka teknikleri stabilite sayılarının tahmini ve güvenilirlik analizi için Mersin yat limanına uygulanmıştır. Taş dolgu kıyı yapılarının ön tasarımı için Van der Meer deney verilerini içeren bir “tasarım yapay sinir ağı” geliştirilerek, bu ağın mühendislik uygulamalarındaki kullanılabilirliği gerçekleştirilmiştir. Ayrıca, güvenilirliğe dayalı tasarımda, ikinci moment yöntemi yerine genetik algoritmanın kullanılmasının global optimum çözümün bulunmasında daha güvenilir sonuçlar vereceği ortaya konmuştur. Deterministik yöntemler yerine doğrusal olmayan yapay zeka tekniklerinin uygulanması ve bu sayede belirsizliklerin azaltılması ya da işlenebilmesi, taş

dolgu dalgakıranların karmaşık modellere gereksinim duyulmadan tasarlanmasını sağlamıştır.

Bilim Kodu : 624.02.03

Anahtar Kelimeler : Yapay zeka, taş dolgu dalgakıran, yapay sinir ağı

Sayfa Adedi : 157

Tez Yöneticisi : Doç. Dr. Can E. Balas

: Prof. Dr. A. Samet Arslan



**DESIGN AND RELIABILITY ANALYSIS OF RUBBLE MOUND
BREAKWATERS BY USING ARTIFICIAL NEURAL NETWORKS, FUZZY
LOGIC SYTEMS AND GENETIC ALGORITHM**

(Ph. D Thesis)

M. Levent KOÇ

**GAZI UNIVERSITY
INSTITUTE OF SCIENCE AND TECHNOLOGY**

October 2002

ABSTRACT

In this study, artificial intelligence techniques were applied to the preliminary design of rubble mound breakwaters and the results obtained were compared with conventional methods. Wave parameters of Alanya region (significant wave height, period and direction) were simultaneously predicted by using feed forward and recurrent neural networks. Artificial intelligence techniques which include feed forward neural networks, fuzzy systems, fuzzy neural networks and genetic algorithm were applied to the stability and reliability analyses of Mersin yacht harbor main breakwater, as a case study. It was found that, in predicting wave parameters, a better performance can be obtained by neural networks than stochastic models and that recurrent neural networks were appropriate for multi step predictions. A “design artificial neural network” which uses Van der Meer’s hydraulic model test data, was developed for the preliminary design of rubble mound coastal structures and it was verified for the design applications. Furthermore it has been showed that, with the application of genetic algorithms in the reliability-based design, more reliable results can be obtained for the optimum global solutions, when compared to the second-order methods. Artificial intelligence techniques can handle more accurately the uncertainties inherent in the design of rubble mound

breakwaters; hence the need of complex models generally used for the design has been significantly decreased.

Science Code : 624.02.03

**Key Words : Artificial intelligence, breakwaters,
neural networks**

Page Number : 157

**Adviser : Ass. Prof. Dr. Can E. Balas
: Prof. Dr. A. Samet Arslan**



TEŞEKKÜR

Bu çalışmanın hazırlanması sırasında her zaman yakın ilgisini ve desteğini gördüğüm aynı zamanda görüşleri ve önerileriyle bu çalışmaya büyük katkılarda bulunan Doç. Dr. Can E. Balas'a teşekkürü bir borç biliyorum. Yapay zeka tekniklerinin uygulanması sırasında önerileriyle katkıda bulunan ve deneyimlerini paylaşan Prof. Dr. A. Samet Arslan'a teşekkürlerimi sunuyorum. Bu çalışmaya değerli yorumlarıyla katkıda bulunan Prof. Dr. Ayşen Ergin'e ayrıca teşekkür ediyorum.



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Eğitim, doğrulama ve test aşamasında kullanılan dalga verilerine ait istatistiki bilgiler.....	38
Çizelge 4.2. Eğitim, doğrulama ve test aşamasında kullanılan rüzgar verilerine ait istatistik bilgiler	39
Çizelge 4. 3. Tek değişkenli yapay sinir ağları ve AR modeller.....	41
Çizelge 4.4. Tek değişkenli yapay sinir ağlarının yapısı ve iterasyon sonuçları	44
Çizelge 4.5. KG eğitim algoritması ile eğitilen tek değişkenli yapay sinir ağlarına ve AR modellere ait kısa tahmin aralıklı test sonuçları.....	45
Çizelge 4.6. MGA eğitim algoritması ile eğitilen tek değişkenli yapay sinir ağlarına ait kısa tahmin aralıklı test sonuçları.....	45
Çizelge 4.7. KG eğitim algoritması ile eğitilen tek değişkenli yapay sinir ağlarına ve AR modellere ait uzun tahmin aralıklı test sonuçları.....	48
Çizelge 4.8. MGA eğitim algoritması ile eğitilen tek değişkenli yapay sinir ağlarına ait uzun tahmin aralıklı test sonuçları	48
Çizelge 4. 9. Çok değişkenli yapay sinir ağları ve ARX modeller.....	53
Çizelge 4. 10. Çok değişkenli yapay sinir ağlarının yapısı ve iterasyon sonuçları.....	53
Çizelge 4.11. KG eğitim algoritması ile eğitilen çok değişkenli yapay sinir ağlarına ve ARX modellere ait kısa tahmin aralıklı test sonuçları.....	54
Çizelge 4.12. MGA eğitim algoritması ile eğitilen çok değişkenli yapay sinir ağlarına ait kısa tahmin aralıklı test sonuçları	55

Çizelge 4.13. KG eğitme algoritması ile eğitilen çok değişkenli yapay sinir ağlarına ve ARX modellere ait uzun tahmin aralıklı test sonuçları	56
Çizelge 4.14. MGA eğitme algoritması ile eğitilen çok değişkenli yapay sinir ağlarına ait uzun tahmin aralıklı test sonuçları	56
Çizelge 5.1. Tasarım parametrelerinin değişim aralıkları	70
Çizelge 5.2. İleri beslemeli denetimli sinir ağı için eğitme aşamasına ait sonuçlar	71
Çizelge 5.3. Esas bileşenler için gerçek değişkenlere bağlı ağırlık faktörleri.....	75
Çizelge 5.4. Toplam veri kümesine ait istatistiki özellikler	77
Çizelge 5.5. Düzenlenmiş veri kümesine ait istatistiki özellikler.....	77
Çizelge 5.6. Düzenlenmiş veri kümesine ait esas bileşenler için gerçek değişkenlere bağlı ağırlık faktörleri.....	77
Çizelge 5.7. Düzenlenmiş veri kümeleri ve esas bileşenler kullanılarak oluşturulan ileri beslemeli denetimli yapay sinir ağlarının eğitilme aşamasına ait sonuçlar	79
Çizelge 5.8. Düzenlenmemiş veri tabanı kullanılarak oluşturulan bulanık sinir ağı için eğitme aşamasına ait sonuçlar	94
Çizelge 5.9. Düzenlenmiş veri tabanı kullanılarak oluşturulan bulanık sinir ağına ait eğitme aşamasına ait sonuçlar	96
Çizelge 5.10. Stabilitate sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması ($H_s=2,5$ m)	97
Çizelge 5.11. Stabilitate sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması ($H_s=5,5$ m)	98
Çizelge 5.12. Stabilitate sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması ($H_s=8,5$ m)	98

Çizelge 5.13. Stabilité sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması ($\text{Cot } \theta=4,0$).....	99
Çizelge 5.14. Stabilité sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması ($\text{Cot } \theta=6,0$).....	99
Çizelge 5.15. Rassal olarak seçilen deney verilerine ait değişim aralıkları.....	108
Çizelge 5.16. Yapay sinir ağı ve Van der Meer denklemleri kullanılarak belirlenen stabilité sayıları ile deney verilerine ait stabilité sayıları için istatistiki parametrelerin değişimi	111
Çizelge 5.17. Mersin yat limanı tasarımı için hesaplanmış farklı yinleme sürelerine ait belirgin dalga yüksekliği ve periyodları	111
Çizelge 5.18. Mersin yat limanı ana dalgakıran koruma tabakası için Van der Meer denklemi ve yapay zeka teknikleri ile elde edilen taş çapları ve ağırlıkları ($T_r=25$ yıl)	112
Çizelge 5.19. Mersin yat limanı ana dalgakıran koruma tabakası için Van der Meer denklemi ve yapay zeka teknikleri ile elde edilen taş çapları ve ağırlıkları ($T_r=50$ yıl)	112
Çizelge 5.20. Mersin yat limanı ana dalgakıran koruma tabakası için Van der Meer denklemi ve yapay zeka teknikleri ile elde edilen taş çapları ve ağırlıkları ($T_r=100$ yıl)	112
Çizelge 5.21. Tasarım değişkenlerine ait istatistiki özellikler	119
Çizelge 5.22. Değişik yöntemlerle elde edilen yıkılma olasılıkları ve tasarım değişkenlerinin yıkılma yüzeyine ait değerleri	120

ŞEKİLLERİN LİSTESİ

Şekil		Sayfa
Şekil 3.1.	Biyolojik ve yapay sinir hücresi	12
Şekil 3.2.	İleri beslemeli denetimli yapay sinir ağı.....	14
Şekil 3.3.	Elman tipi yapay sinir ağı.....	17
Şekil 3.4.	VE tipi bulanık sinir hücresi	24
Şekil 3.5.	VEYA tipi bulanık sinir hücresi.....	24
Şekil 3.6.	Bulanık sinir ağı	26
Şekil 3.7.	Çaprazlamanın şematik olarak gösterimi	29
Şekil 4.1.	Yönsel dalga ölçerin konumu.....	34
Şekil 4.2.	Alanya dalga ölçüm istasyonundaki eksik verilerin gözlenme sıklığı.....	35
Şekil 4.3.	Eğitme veri kümesine için belirgin dalga yüksekliği değerlerine ait otokorelasyon ve kısmi otokorelasyon fonksiyonları.....	42
Şekil 4.4.	Eğitme veri kümesine için ortalama dalga periyodu değerlerine ait otokorelasyon ve kısmi otokorelasyon fonksiyonları.....	42
Şekil 4.5.	Eğitme veri kümesine için dalga yönü değerlerine ait otokorelasyon ve kısmi otokorelasyon fonksiyonları.....	43
Şekil 4.6.	Eğitme veri kümesi için belirgin dalga yüksekliği değerleriyle rüzgar yönü (a) ve hızı (b) arasındaki çapraz korelasyon fonksiyonları.....	50
Şekil 4.7.	Eğitme veri kümesi için ortalama dalga periyodu değerleriyle rüzgar yönü (a) ve hızı (b) arasındaki çapraz korelasyon fonksiyonları	51
Şekil 4.8.	Eğitme veri kümesi için dalga yönü değerleriyle rüzgar yönü arasındaki çapraz korelasyon fonksiyonları	51

Şekil 4.9.	Tek değişkenli yapay sinir ağlarına bağlı olarak tahmin edilen belirgin dalga yüksekliği değerleri için determinasyon katsayılarının değişimi	58
Şekil 4.10.	Tek değişkenli yapay sinir ağlarına bağlı olarak tahmin edilen dalga periyodu değerleri için determinasyon katsayılarının değişimi	58
Şekil 4.11.	Çok değişkenli yapay sinir ağlarına bağlı olarak tahmin edilen belirgin dalga yüksekliği değerleri için determinasyon katsayılarının değişimi	59
Şekil 4.12.	Çok değişkenli yapay sinir ağlarına bağlı olarak tahmin edilen dalga periyodu değerleri için determinasyon katsayılarının değişimi	59
Şekil 4.13.	1 nolu test kümesi için tek değişkenli yapay sinir ağları ile yapılan kısa ve uzun aralıklı belirgin dalga yüksekliği tahminlerinin ölçülen değerlerle karşılaştırılması	61
Şekil 4.14.	1 nolu test kümesi için tek değişkenli yapay sinir ağları ile yapılan kısa ve uzun aralıklı dalga periyodu tahminlerinin ölçülen değerlerle karşılaştırılması	61
Şekil 4.15.	1 nolu test kümesi için çok değişkenli Elman tipi sinir ağı ile yapılan kısa ve uzun aralıklı belirgin dalga yüksekliği tahminlerinin ölçülen değerlerle karşılaştırılması	62
Şekil 4.16.	1 nolu test kümesi için çok değişkenli Elman tipi sinir ağı ile yapılan kısa ve uzun aralıklı dalga periyodu tahminlerinin ölçülen değerlerle karşılaştırılması	62
Şekil 4.17.	4 nolu test kümesi için çok değişkenli Elman tipi sinir ağı ile yapılan kısa ve uzun aralıklı belirgin dalga yüksekliği tahminlerinin ölçülen değerlerle karşılaştırılması	63
Şekil 4.18.	4 nolu test kümesi için çok değişkenli Elman tipi sinir ağı ile yapılan kısa ve uzun aralıklı dalga periyodu tahminlerinin ölçülen değerlerle karşılaştırılması	63

Şekil 5.1.	Taş dolgu dalgakıranlarda farklı hasar tipleri.....	65
Şekil 5.2.	Mersin deniz yöresinde, en yüksek belirgin dalga yükseklikleri Fisher Tippet Tip I (Gumbel) olasılık dağılımı	67
Şekil 5. 3.	İleri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı	71
Şekil 5. 4.	Van der Meer denklemleri ile tahmin edilen stabilite sayılarına ait dağılım diyagramı (N=1000)	72
Şekil 5. 5.	Van der Meer denklemleri ile tahmin edilen stabilite sayılarına ait dağılım diyagramı (N=3000)	72
Şekil 5.6.	Girdi vektörlerinin oluşturduğu veri tabanına ait verilerin birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımı.....	74
Şekil 5.7.	Esas bileşenlere ait varyans değerleri.....	75
Şekil 5.8.	Düzenlenmiş veri kümesi için girdi vektörlerinin oluşturduğu veri tabanına ait verilerin birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımı.....	78
Şekil 5.9.	Düzenlenmiş veri kümesi için esas bileşenlere ait varyans değerleri	78
Şekil 5. 10.	Düzenlenmiş veri tabanı ile eğitilen (gerçek veri + rassal değişken) ve girdileri P, S, $\cot \theta$, N ve ϵ_m değerlerinden oluşan ileri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı.....	80
Şekil 5.11.	Van der Meer denklemleri ile tahmin edilen stabilite sayılarına ait dağılım diyagramı	80
Şekil 5. 12.	Düzenlenmiş veri tabanı ile eğitilen (gerçek veri + rassal değişken) ve girdileri P, S, $\cot \theta$ ve ϵ_m değerlerinden oluşan ileri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı.....	81
Şekil 5.13.	Düzenlenmiş veri tabanı ile eğitilen ve girdileri ilk beş esas bileşenden oluşan ileri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı.....	82

Şekil 5.14.	Düzenlenmiş veri tabanı ile eğitilen ve girdileri ilk dört esas bileşenden oluşan ileri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı.....	82
Şekil 5.15.	Bulanık sistem.....	84
Şekil 5.16.	Belirgin dalga yüksekliğine (H_s) ait bulanık alt kümeler.....	85
Şekil 5.17.	Ortalama dalga periyoduna (T) ait bulanık alt kümeler.....	86
Şekil 5.18.	Hasar seviyesine (S) ait bulanık alt kümeler	86
Şekil 5.19.	Stabilite sayısına (N_s) ait bulanık alt kümeler	87
Şekil 5.20.	Adeli-Hung Algoritma ile kombine edilmiş bulanık sistem.....	88
Şekil 5.21.	Adeli-Hung Algoritma ile kombine edilen bulanık sistem için stabilite sayısına (N_s) ait bulanık alt kümeler ($P=0,1$; $N=3000$; $\cot \theta=2,0$)	89
Şekil 5.22.	Adeli-Hung Algoritma ile kombine edilen bulanık sistem için stabilite sayısına (N_s) ait bulanık alt kümeler ($P=0,1$; $N=3000$; $\cot \theta=4,0$)	90
Şekil 5.23.	Adeli-Hung Algoritma ile kombine edilen bulanık sistem için stabilite sayısına (N_s) ait bulanık alt kümeler ($P=0,1$; $N=3000$; $\cot \theta=6,0$)	90
Şekil 5.24.	Bulanık sinir ağı için permeabilite katsayısına (P) ait bulanık alt kümeler.....	91
Şekil 5.25.	Bulanık sinir ağı için hasar seviyesine (S) ait bulanık alt kümeler.....	92
Şekil 5.26.	Bulanık sinir ağı için dalga sayısına (N) ait bulanık alt kümeler	92
Şekil 5.27.	Bulanık sinir ağı için eğim ($\cot \theta$) değerine ait bulanık alt kümeler.....	93
Şekil 5.28.	Bulanık sinir ağı için Iribarren sayısına (ϵ_m) ait bulanık alt kümeler	93

Şekil 5.29.	Girdileri P, cot θ , S, N, ϵ_m olan ve düzenlenmemiş veri tabanı kullanılarak eğitilen bulanık sinir ağı ile belirlenen stabilite sayıları için dağılım diyagramı	95
Şekil 5.30.	Girdileri P, cot θ , S, N, ϵ_m olan ve düzenlenmiş veri tabanı kullanılarak eğitilen bulanık sinir ağı ile belirlenen stabilite sayıları için dağılım diyagramı	95
Şekil 5.31.	Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=2,5$ m; $P=0,1$; cot $\theta=2,0$; $N=3000$; $T=8$ sn)	100
Şekil 5.32.	Bulanık sistem ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=2,5$ m; $P=0,1$; cot $\theta=2,0$; $N=3000$; $T=8$ sn)	100
Şekil 5.33.	Bulanık sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=2,5$ m; $P=0,1$; cot $\theta=2,0$; $N=3000$; $T=8$ sn)	101
Şekil 5.34.	Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=5,5$ m; $P=0,1$; cot $\theta=2,0$; $N=3000$; $T=8$ sn)	101
Şekil 5.35.	Bulanık sistem ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=5,5$ m; $P=0,1$; cot $\theta=2,0$; $N=3000$; $T=8$ sn)	102
Şekil 5.36.	Bulanık sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=5,5$ m; $P=0,1$; cot $\theta=2,0$; $N=3000$; $T=8$ sn)	102
Şekil 5.37.	Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=8,5$ m; $P=0,1$; cot $\theta=2,0$; $N=3000$; $T=8$ sn)	103
Şekil 5.38.	Bulanık sistem ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=8,5$ m; $P=0,1$; cot $\theta=2,0$; $N=3000$; $T=8$ sn)	103
Şekil 5.39.	Bulanık sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=8,5$ m; $P=0,1$; cot $\theta=2,0$; $N=3000$; $T=8$ sn)	104

Şekil 5.40.	Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=4,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)	104
Şekil 5.41.	Bulanık sistem ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=4,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)	105
Şekil 5.42.	Bulanık sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=4,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)	105
Şekil 5.43.	Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=6,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)	106
Şekil 5.44.	Bulanık sistem ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=6,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)	106
Şekil 5.45.	Bulanık sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=6,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)	107
Şekil 5.46.	Permeabilite katsayısı (P) ile stabilite sayısı (N_s) arasındaki ilişkinin yapay sinir ağı ve Van der Meer denklemleri için karşılaştırılması ($\cot \theta=2,0$; $\epsilon_m=1,0$; $S=2,0$; $N=2000$).....	109
Şekil 5.47.	Iribarren sayısı (ϵ_m) ile stabilite sayısı (N_s) arasındaki ilişkinin yapay sinir ağı ve Van der Meer denklemleri için karşılaştırılması ($\cot \theta=2,0$; $P=0,1$; $S=2,0$; $N=2000$)	109
Şekil 5.48.	Dalga sayısı (N) ile stabilite sayısı (N_s) arasındaki ilişkinin yapay sinir ağı ve Van der Meer denklemleri için karşılaştırılması ($\cot \theta=2,0$; $\epsilon_m=1,0$; $S=2,0$; $P=0,1$)	110
Şekil 5.49.	Eğim ($\cot \theta$) ile stabilite sayısı (N_s) arasındaki ilişkinin yapay sinir ağı ve Van der Meer denklemleri için karşılaştırılması ($P=0,1$; $\epsilon_m=7,0$; $S=2,0$; $N=2000$)	110
Şekil 5.50.	Mersin Yat Limanı için Hasar seviyesinin $S=2$ olması halinde Van der Meer Denklemleri ve yapay zeka teknikleri ile belirlenen nominal taş çaplarının yineleme sürelerine bağlı değişimi.....	114

Şekil 5.51.	Mersin Yat Limanı için Hasar seviyesinin $S=10$ olması halinde Van der Meer Denklemleri ve yapay zeka teknikleri ile belirlenen nominal taş çaplarının yineleme sürelerine bağlı değişimi	114
Şekil 5.52.	İki değişkenli performans fonksiyonu için güvenilirlik indeksi.....	117
Şekil 5.53.	Uygunluk fonksiyonu değerlerinin iterasyon sayısına bağlı değişimi	121
Şekil 5.54.	Güvenirlik indeksi değerlerinin genetik algoritma için iterasyon sayısına bağlı değişimi.....	121
Şekil 5.55.	Mersin Yat Limanına için uygulanmış Monte Carlo Benzeşimi sonucunda elde edilmiş performans fonksiyonu değerlerinin gözlenme sıklığı	123
Şekil 5.56.	Amaç fonksiyonunun belirgin dalga yüksekliği ve eğim değerlerine bağlı değişimi	124
Şekil 5.57.	Genetik algoritma ile buluna en uygun dizilerin belirgin dalga yüksekliği ve eğim değerleri için dağılımı	124
Şekil 5.58.	Gradyen azalma algoritması ile iteratif çözümün dalga yüksekliği ve eğim değerleri için değişimi	125
Şekil 5.59.	İkinci moment yöntemi ile iteratif olarak elde edilen yıkılma yüzeyi için dalga yüksekliği ve eğim değerlerinin durumu	125

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simge	Açıklama
A	Dalgakıran kesitindeki hasar alanı
b_k	ARX model parametresi
C	Ceza fonksiyonu parametresi
D_{n50}	Koruma tabakası taşının çapı
F	Uygunluk fonksiyonu
f_{xi}	Olasılık yoğunluk fonksiyonu
G	Kısıtlılık fonksiyonu
g	Limit durum fonksiyonu
g_g	Yerçekimi ivmesi
H_s	Belirgin dalga yüksekliği
K_D	Stabilite katsayısı
N	Fırtınadaki dalga sayısı
$\tilde{N}$	Bulanık alt kümedeki eleman sayısı
n	Temel değişken sayısı
P	Permeabilite katsayısı
P_1	Ceza değeri
P_f	Yıkılma olasılığı
P_o	Ceza değeri
P_r	Güvenirlilik

p	Atoregresif modelin mertebesi
q	Hareketli ortalama modelin mertebesi
R	Korelasyon katsayısı
$\tilde{R}$	Bulanık kural
$\tilde{R}_b$	Bulanık kural tabanı
$\tilde{R}_i(x,y)$	Bulanık ilişki fonksiyonu
r	Determinasyon katsayısı
S	Hasar seviyesi
$\tilde{S}$	$\tilde{S}$ norm operatör
T	Dalga periyodu
$\tilde{T}$	$\tilde{T}$ norm operatör
T_m	Ortalama dalga dönemi
T_r	Yineleme süresi
U	Rüzgar hızı
UD	Rüzgar yönü
W	Taş ağırlığı
WD	Dalga yönü
w	Vektörel olarak ağırlık faktörü
$\bar{x}$	Gerçek verilere ait ortalama değer
$\hat{x}_i$	Tahmin edilen değer
$x_k h_s y_z$	Sinir ağının yapısı
Y	Yüksek
y'	Bulanık çıktının kesin değeri

Z	Standart deęiřken
z	Yapay sinir aęının ıktı katmanındaki hcre sayısı
α	Momentum katsayısı
α_i	Ynsel kosns deęerleri
$\tilde{a}$	yelik fonksiyonu parametresi
β	Gvenirlik indeksi
β_k	Fletcher-Reeves faktr
$\tilde{\beta}$	yelik fonksiyonu parametresi
$\tilde{\gamma}$	yelik fonksiyonu parametresi
Δ	Koruma tabakası tařının greceli yoęunluęu
ϵ_c	Iribarren parametresinin kritik deęeri
ϵ_m	Iribarren parametresi
η	ęrenme oranı
η_k	k'inci iterasyondaki ęrenme oranı
θ	ARMA model parametresi
$\tilde{\mu}_A(x)$	yelik fonksiyonu
$\tilde{\mu}_{gen}$	gen yelik fonksiyonu
$\tilde{\mu}_{R_i}(x,y)$	Bulanık iliřki yelik fonksiyonu
$\tilde{\mu}_{S\ tipi}$	S tipi yelik fonksiyonu
μ_{xi}	Ortalama deęer
$\tilde{\mu}_y$	Bulanık sistem ıktısına ait yelik fonksiyonu
σ_{xi}	Standart sapma

ϕ	ARMA model parametresi
∇E	Karesel hata fonksiyonunun gradyeni
$\nabla J(w)$	Performans indeksinin gradyeni
$\vee$	Maksimum operatörü
$\wedge$	Minimum operatörü
$(\circ)$	Maksimum-minimum operatörü
$(\cdot)$	Cebirsel çarpım operatörü
$(\cdot)_{sm}$	Ortalama değer
$(\cdot)_{smax}$	Maksimum değer
$(\cdot)_{smin}$	Minimum değer
$(\cdot)_{ssd}$	Standart sapma

Kısaltmalar

AR	Atoregresif model
ARMA	Atoregresif hareketli ortalama model
ARX	Çok değişkenli otoregresif model
ÇD	Çok düşük
ÇY	Çok yüksek
D	Düşük
ED	En düşük
ETSA	Elman tipi sinir ağı
EY	En yüksek
İBSA	İleri beslemeli denetimli sinir ağı
KG	Konjuge gradyen

KH	Karesel ortalama hata
MH	Mutlak hata
MA	Hareketli ortalama model
MGA	Momentum katsayılı gradyen azalma
O	Orta
OKF	Otokorelasyon fonksiyonu



1.GİRİŞ

İnsan düşüncesini ve davranışını taklit edebilen sistemlerin geliştirilmesine yönelik çalışmaların tümü yapay zeka olarak tanımlanabilir. Yapay sinir ağları (artificial neural networks), bulanık mantık (fuzzy logic) ve genetik algoritmalar (genetic algorithms) farklı mühendislik alanlarında olduğu kadar inşaat mühendisliğinin değişik alanlarında da (CCP, 1993; Pham and Pham, 1999) son yıllarda yaygın olarak kullanılan yapay zeka uygulamaları/teknikleridir. Yapay sinir ağları, biyolojik sinir hücrelerinin basitleştirilmiş olarak modellenmesi yardımıyla öğrenen sistemlerin geliştirilmesinde kullanılırken; bulanık mantık yardımıyla doğal dil işleyebilen ya da düşünebilen sistemlerin geliştirilmesi amaçlanmaktadır. Genetik algoritmalar ise “doğal seçim” sürecinin bilgisayar ortamında benzeştirilmesine dayanan sezgisel bir arama yöntemidir.

Yapay sinir ağları, bulanık mantık ve genetik algoritmaların, birbirinden tümüyle farklı uygulamalar olmasına karşın, belirsizlikler üzerine kurulan sistemler olması bu tekniklerin ortak yönü olarak değerlendirilebilir. Başka bir deyişle, klasik yöntemlerde ortaya çıkan belirsizlikler istenmeyen ve ayrıca değerlendirilmesi gereken durumlarken; yapay zeka teknikleri belirsizlikleri içeren ve işleyen uygulamalardır.

Mühendislik problemlerindeki belirsizliklerin kaynağı, model ve modelin içerdiği parametreler olup sözkonusu belirsizlikler genellikle olasılık teorisi ve istatistiksel yöntemler yardımıyla gözönüne alınmaktadır. Örneğin, problemin içerdiği parametrelerin (değişkenlerin) rassal bir yapıya sahip olmasından kaynaklanan belirsizlikler olasılık dağılımları ile dikkate alınırken; Bayes karar teorisi, belirsizlik ortamında karar verilebilmesine olanak sağlamaktadır. Belirsizlikler altında ortaya çıkacak başarısızlıklar (risk) ise güvenlik analizi yardımıyla belirlenmektedir. Özellikle karmaşık ve modelleme olanaklarının zor olduğu birçok mühendislik probleminin çözümünde, geliştirilen modelin yetersiz olması önemli bir belirsizlik nedeni olmakla birlikte çözüm sırasında yapılacak kabuller veya basitleştirmeler de belirsizliği arttıran faktörlerdir.

Bir mühendislik yapısının tasarımında karşılaşılan belirsizlikler, istatistiksel yöntemler yardımıyla gözönüne alınmasına karşılık modelin içerdiği parametrelerin rassal değişken olması da başka bir belirsizlik kaynağı olarak verilebilir. Bu tür yöntemlerde, tasarım değişkenleri belirli olasılık dağılımları ile ifade edilmesine karşın değişkenlere ait istatistiki bilgilerin yetersiz olması ve çoğunlukla ortalama ve standart sapma değerleriyle sınırlı kalması belirsizliğe neden olabilmektedir.

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 ağı eğitilmesi yoluyla problemlere çözüm getirebilmesidir. Yapay sinir ağlarının en önemli dezavantajı ise eğitime aşamasının uzun zaman alabilmesidir. Bunun nedenleri, uygun ağ yapısının belirlenmesinde kesin kuralların olmayışı ve genellikle katman ve yapay sinir hücresi sayısı ile eğitime algoritması ve parametrelerinin deneme-yanılma yoluyla saptanması; uygun sonuçların alınabilmesi için mevcut veri tabanının detaylı bir analizine ihtiyaç duyulabilmesidir. Ayrıca, yapay sinir ağlarının eğitime aşamasında kullanılacak veri tabanının tüm değişkenler için geniş bir değişim aralığını kapsamaması dikkat edilmesi gereken noktalardan birini oluşturmaktadır.

Bulanıklığın, genel olarak kesinlik içermeyen bilgiyi başka bir deyişle belirsizliği ifade ettiği söylenebilir. Bulanık mantık ise, sözel (linguistik) değişkenler kullanarak kesinlikler yerine belirsizliklerle çalışan bir yapay zeka tekniği olarak tanımlanabilir. Sözel bir değişkenin tipik değeri, örneğin “sıcak” veya “soğuk” gibi sözcüklerle ifade edilir ve bulanık kümelerin üyelik fonksiyonları ile temsil edilir. Bulanık mantığın klasik matematiksel yöntemlerden farkı, kesinliklerle çalışılmaması ve niteliksel tanımlamalara olanak sağlamasıdır. Belirsizliklerin matematiksel olarak ifade edilebilmesi, karmaşık sistemlerin modellenmesine bulanık mantığın getirdiği en büyük kolaylık olarak değerlendirilebilir. Ayrıca, bulanık mantığın sözel bilginin

kullanılması açısından Bayesian teoriden farkı, olasılıkçı bir yaklaşıma ihtiyaç duymaması (Rojas, 1996) ve istatistik yöntemlerden farklı olarak olayın meydana gelmesindeki belirsizlik yerine olayın kendisine ait belirsizliği gözönüne almasıdır: İstatistiksel yöntemler, rassal değişkenlere bağlı belirsizlik içeren durumları olasılık teorisine göre modellerken; bulanık mantık, rassal olmayan sözel değişkenlerin (doğal dilin) içerdiği belirsizlikleri işlemektedir. Örneğin, rassal bir değişken için verilen olasılık değeri, olayın gözlenme sıklığını belirtmesine karşın değişkenin bir bulanık alt küme içinde (sıcak, soğuk, ılık vb) üyelik derecesi ile tanımlanması değişken için sözkonusu kümeye aitliği ifade etmektedir. Gözönüne alınan olayın çok karmaşık olması ve yeterli bilginin bulunmaması ve gözönüne alınan sisteme ait değişkenlerin yeterince tanımlanamaması bulanık mantığın en geçerli olduğu durumlar olarak sıralanabilir (Moshgbar et. al., 1995). Başka bir deyişle, bulanık mantık, karmaşık durumlar karşısında insanın düşünme ve karar verebilme yeteneğinin sözel değişkenler yardımıyla kullanılmasını amaçlamaktadır. Bulanık sistemler ve bulanık sinir ağları, bulanık mantığın yapay zeka alanındaki kullanımlarına örnek olarak verilebilir.

Bulanıklaştırma, bulanık kural tabanı ve durulaştırma, bulanık sistemler yardımıyla modellemenin genel aşamalarını oluşturmaktadır. Bulanık sistemler, sözel değişkenler yardımıyla oluşturulan bulanık kural tabanı ile belirsizlikleri (doğal dili) işleyen sistemler olup klasik modelleme yöntemlerinde kullanılmayan deneyime ve sezgiye dayanan uzman bilgisinden yararlanılmasını amaçlamaktadır. Örneğin, EĞER hava “sıcak” İSE fan hızı “yüksek”tir ifadesi bulanık bir kuraldır ve bulanık kural tabanları genellikle birden çok bulanık kuraldan meydana gelir. Ancak, bu tip sistemler, yapay sinir ağları gibi bir veri tabanına bağlı olarak öğrenen bir sistem olmayıp kural tasarımına dayanan sistemlerdir. Sistemin girdi ve çıktılarına ait deneysel verilerin olması halinde bulanık mantık ve yapay sinir ağları, bulanık sinir ağları şeklinde entegre bir sistem olarak tasarlanabilmektedir. Böylece girdi ve çıktıları bulanıklaştırılabilen ve öğrenebilen sistemler geliştirilebilmekte ve her iki tekniğin avantajlı yanları biraraya getirilebilmektedir. Bulanık sinir ağlarında, ağı girdi ve çıktıları bulanıklaştırılmakla birlikte genellikle yapay sinir hücrelerinin yerini bulanık sinir hücreleri almaktadır. Yapay ve bulanık sinir hücreleri, biyolojik

sinir hücresinin matematiksel olarak basitleştirilmiş şekilde modellenmesine dayanmakla birlikte her iki sinir hücresinin verileri işleme biçimi değişiklik göstermektedir: Hücreye gelen uyarımlar, yapay sinir hücresinde esas olarak doğrusal olmayan bir fonksiyon yardımıyla işlenirken; bulanık sinir hücresi, uyarımları bulanık operatörler yardımıyla işlemektedir.

Genetik algoritmalar, rassal bir arama yöntemidir ve biyolojik sistemlerin “doğal seçim” sürecinin genetik operatörler yardımıyla benzeştirilmesine dayanmaktadır. Genetik algoritmaları diğer arama yöntemlerinden ayıran en önemli özelliklerden biri türevler kullanılmaksızın yalnızca amaç fonksiyonunun değerlerini kullanması; aynı anda tek bir noktada değil birçok noktada çözüm araması ve bu yolla, özellikle karmaşık (belirsiz) çözüm uzaylarında, daha yüksek bir olasılıkla global optimum çözüme ulaşabilmesidir.

Yapay zeka teknikleri, birçok alanda geniş bir kullanım alanı bulmasına karşın halen gelişimini sürdüren bir disiplin olup sözkonusu tekniklerin avantajları yanında getirdiği dezavantajlar da vardır: Yapay zeka tekniklerinin hiçbirinin çözümü garanti etmemesi ve yapay sinir ağlarının eğitilme aşamasının çok uzun zaman alabilmesi bunlara örnek olarak verilebilir. Ancak, yüksek derecede belirsizlik gösteren (karmaşık) mühendislik problemlerinin çözümünde belirsizliklerin azaltılmasına ve değerlendirilmesine yönelik klasik yaklaşımlar, çoğunlukla daha karmaşık ve zaman-maliyet açısından ekonomik olmayan çözümlere neden olabilmektedir. Bu nedenle, yapay zeka tekniklerinin, belirsizlikler gözönüne alındığında, klasik yöntemlerin sağlayamayacağı avantajlara sahip olduğu söylenebilir; ancak, yapay zeka teknikleri, mevcut yöntemlere tümüyle alternatif bir yöntem olarak değerlendirilmemelidir.

Deniz Mühendisliği Yapılarının Tasarımı

Taş dolgu dalgakıranlar, deniz mühendisliğinde yüksek maliyete ve Türkiye’de en çok hasar olasılığına sahip yapılardır, ayrıca dayanım ve olası yük değerlerine bağlı yoğun belirsizliklerler içermektedirler. Kıyı yapıları, ön tasarım aşamasında genellikle yarı-deneysel denklemler yardımıyla (Hudson, 1953; Van der Meer, 1988)

deterministik olarak tasarlanmakta ancak belirsizlik aralıkları gözönüne alınmamaktadır. Bu nedenle tasarım sırasında belirsizliklerin de dikkate alındığı istatistiksel yöntemlerden yararlanılması zorunludur (Balas and Ergin, 2002). Tasarım aşamasında kullanılan eşitliklerde belirsizlik nedeni geniş bir değer aralığının (değişkenliğin) eşitlik içerisinde ortalama değerlerle ifade edilmesidir (Balas, 1998). Ayrıca, tasarım parametreleri olan yük ve dayanım değişkenleri de belirsizlik kaynağı olup bu tip belirsizlikler aşağıda başlıklar halinde verilmiştir (Balas, 1998). Burada, yük değişkenleri, yapıya etkiyen yük veya yüklere karşılık gelirken; dayanım değişkenleri, yapıyı oluşturan eleman veya elemanların dayanım/yük taşıma kapasitelerini ifade etmektedir ve yapının emniyeti (güvenirliliği) yük ve dayanım değişkenlerinin bileşik etkisine bağlıdır.

1. Yük değişkenleri olan belirgin dalga yüksekliği, ortalama dalga sayısı ve derin sudaki dalga dikliğine bağlı belirsizlikler: Tasarım dalgası yüksekliğinin saptanmasında genellikle rüzgar verilerinden yararlanılmakta olup rüzgar-dalga ilişkisinin karmaşık yapısı (WMO, 1988) önemli bir belirsizlik nedeni olarak görülebilir. Ayrıca rüzgar verilerinin niteliği, tahmin modeli, yakıncıyı hesapları, ekstrem dalga istatistikleri ve kullanılan istatistik yöntemler de diğer belirsizlik kaynakları olarak değerlendirilebilir.

Gözönüne alınan bölge için proje dalga yüksekliğinin tahmininde Meteoroloji İstasyonuna ait rüzgar verilerinden yararlanılmaktadır. Ancak, genellikle karada ölçülen rüzgar hızlarının, atmosferik sınır tabakası ve yeryüzünün pürüzlülük özelliklerine bağlı olarak deniz yüzeyinde daha küçük değerler alacak olması bu değerlerin artırılmasının gerektirir. Bu işlem için değişik deneysel ifadeler mevcut olup, örnek olarak Hsu (1985) tarafından önerilen ifade verilebilir. Artırılmış rüzgar hızı ve rüzgar yönü (bir fırtına süresince) dalga modelinin girdi parametreleridir. Türkiye'de meteoroloji istasyonlarına ait rüzgar verilerinin güvenilirliği istasyon özelliklerine bağlı olarak büyük değişiklikler gösterebilmektedir (Ergin and Özhan, 1986).

Dalga tahmin modelinde kullanılan PM (Pierson Moskowitz) dalga spektrum modeli tam gelişmiş deniz koşullarına uygulanmakla birlikte gelişmekte olan deniz koşullarına ise düzenlenerek uygulanabilmektedir. Model içerisinde, rüzgar hızlarının etkin kabarma (feç) mesafesi boyunca alınan ve saatlik ortalama hızlar olduğu kabul edilmektedir ve modelin güvenilirliği meteoroloji istasyonunundan elde edilen rüzgar verilerinin niteliğine bağlı olmaktadır

Değişkenlerin gerçek dağılımları yerine değişik grafik yöntemler (Weibull, Bernard ve Gringorten vb) ile belirlenen ekterm değer dağılımları (Wang and Le Mehaute, 1983) başka bir belirsizlik nedeni olarak verilebilir.

2. Dayanım değişkenlerinin neden olduğu belirsizlikler: Taş dolgu dalgakıranlar için dayanım değişkenleri, nominal taş çapı, koruma tabakasının eğimi ve geçirgenlik (permeabilite) katsayısıdır. Ocak taşının niteliği, koruma tabakasının eğimindeki sapmalar ve yapının gerçek yapısal geçirgenlik değeri dalgakıranların performansını etkileyen faktörlerdir.

Koruma tabakası inşasında kullanılan nominal taş çapının gösterdiği değer aralığının, alt ve üst sınır değerleri arasındaki değişimi bilinmediğinden, düzgün yayılı bir dağılım gösterdiği kabul edilebilir. Ayrıca, koruma tabakasının eğiminde, inşa sırasında ve yersel olarak ortaya çıkacak sapmaların yaklaşık olarak normal dağılım gösterdiği de düşünülebilir.

Çalışmanın Amacı ve Kapsamı

Tasarım aşamasında belirsizliğin kara yapılarına oranla taş dolgu dalgakıranlarda çok daha yüksek olduğu görülmekte ve bu durum yapay zeka tekniklerinin, kıyı yapılarının tasarımına uygulanmasını zorunlu hale getirmektedir. Belirsizliklerin gözönüne alınmasında, istatistiksel yöntemlerle birlikte (Balas et. al., 1995; Ergin and Balas, 1998; Ergin and Balas, 1997; Balas and Ergin, 1997) yapay zeka tekniklerinin de kullanılması, yüksek maliyetli olan bu yapıların daha ekonomik ve daha emniyetli bir şekilde tasarımına katkıda bulunacaktır. Bu tezde, Türkiye'deki

ilk uygulamalardan biri olmak üzere, taş dolgu dalgakıranların farklı tasarım aşamalarında (eksik dalga ölçümlerinin tamamlanması ve güvenilirliğe dayalı ön tasarım) yapay zeka teknikleri (yapay sinir ağları, bulanık mantık ve genetik algoritmalar) dünya literatürü ile paralel olarak uygulanmış ve elde edilen sonuçlar klasik yöntemlerle karşılaştırılmıştır.

Alanya deniz yöresindeki belirgin dalga yüksekliği, ortalama dalga periyodu ve dalga yönü ölçümlerinin çeşitli nedenlerle kesintiye uğramasından kaynaklanan eksik verilerin ileri ve geri beslemeli yapay sinir ağları kullanılarak tahmini yapılmıştır. Taş dolgu dalgakıranların tasarımında, Van der Meer eşitliklerine alternatif olarak ileri beslemeli denetimli sinir ağları, bulanık sistemler ve bulanık sinir ağlarından oluşan yapay zeka teknikleri uygulanarak değişik yapay zeka tekniklerinin performansları değerlendirilmiş; ayrıca deterministik tasarım sonuçları yapay zeka tekniklerinin sonuçları ile karşılaştırılmıştır.

Bu çalışmanın kapsamında, ikinci bölümde yapay zeka tekniklerinin kıyı mühendisliği alanında yer alan uygulamaları ele alınmış ve bu çalışmalardan elde edilen sonuçlar değerlendirilmiştir. Yapay sinir ağları, bulanık mantık uygulamaları olan bulanık (uzman) sistemler ve bulanık sinir ağları ile birlikte genetik algoritmalar üçüncü bölümde özetlenmiştir. Dördüncü bölümde, ileri ve geri beslemeli denetimli yapay sinir ağları dalga parameterlerinin tahmininde kullanılmıştır. Bulanık mantığın, taş dolgu dalgakıranların tasarımına yönelik olarak uygulanması çalışmanın beşinci bölümünü oluşturmuş ve taş dolgu dalgakıranların güvenlik analizi, genetik algoritmalar ile gerçekleştirilmiştir.

2. LİTERATÜR TARAMASI

Son yıllarda, birçok mühendislik probleminin çözümünde kullanılan yapay zeka tekniklerinden sadece yapay sinir ağları, karmaşık ve yüksek derecede belirsizlikler içeren kıyı mühendisliği problemlerine değişik araştırmacılar tarafından uygulanmıştır. Elde edilen sonuçlar, yapay sinir ağlarının klasik yöntemlere alternatif olarak uygulanabileceğini ortaya koymuştur. Söz konusu çalışmalar, aşağıda sıralanmıştır:

Taş dolgu dalgakıranların tasarımı üzerine yapılan tek çalışmada (Mase et. al., 1995), yapay sinir ağları kullanılarak taş dolgu dalgakıranlar için denge (stabilite) analizi yapılmıştır. Çalışmada ileri beslemeli denetimli (multi layer feed forward) bir yapay sinir ağı kullanılmış ve Van der Meer'in model deneylerinden elde edilen verilerle eğitilmiştir. Çalışmanın amacı, stabilite sayısının ve hasar seviyesinin tahminidir. Stabilite sayısının tahmininde, permeabilite katsayısı, hasar seviyesi, Iribarren sayısı ve dalga sayısı ağı girdileri olarak alınmıştır. Ayrıca, boyutsuz su derinliği ve spektral şekil parametresi de mevcut girdilere ilave edilerek stabilite sayıları tahmin edilmiştir. Tahmin edilen değerlerin model deneylerinden elde edilen değerlerle uyumlu olduğu gözlenmiş ancak yapay sinir ağların performansı Van der Meer denklemlerine kıyasla düşük bulunmuştur.

Belirgin dalga yüksekliklerinin değişik zaman aralıklarında tahmini üzerine Yanam Körfezi'nde (Hindistan) yapılan çalışma (Deo and Naidu, 1999), yapay sinir ağlarının zaman serilerinin tahmininde kullanılmasının ilk örneğini oluşturmaktadır. Bu çalışmada, belirgin dalga yüksekliklerinin üç saatlik, altı saatlik, 12 saatlik ve günlük ortalama değerleri kullanılarak aynı zaman aralıklarına ait bir sonraki dalga yükseklikleri ileri beslemeli denetimli yapay sinir ağları yardımıyla tahmin edilmiştir. Ağların eğitilmesi aşamasında, üç farklı algorithmadan yararlanılmış ve tahmin sonuçları eğitme algoritmaları da dikkate alınarak değerlendirilmiştir. Ayrıca, belirgin dalga yükseklikleri istatistiksel AR (Autoregressive Model) modeller kullanılarak da tahmin edilmiş ve yapay sinir ağları ile elde edilen sonuçların, AR modeliyle elde edilenlere göre daha yüksek korelasyon gösterdiği belirtilmiştir.

Mase ve Kitano (1999) tarafından yapılan bir çalışmada yapay sinir ağıları kompozit dalgakıranların tasarımında kullanılmıştır. Bu çalışmada, ileri beslemeli denetimli yapay sinir ağıları yardımıyla, kompozit dalgakıranlarda dinamik basınç kuvveti boyutsuz tasarım değişkenlerinden yararlanılarak tahmin edilmiştir.

Tsai ve Lee (1999) tarafından yapılan çalışmada ileri beslemeli denetimli yapay sinir ağı kullanılarak Taichung Limanında ve Mirtuor Bölgesinde (Tayvan) gel-git seviyeleri tahmin edilmiştir. Çalışmada birer saatlik aralıklarla ölçülmüş bir yıllık veriler kullanılmış ve son iki saatlik verilerden yararlanılarak daha sonraki bir saatlik seviye değerleri tahmin edilmiştir; ağı bir günlük verilerle eğitilmesi halinde bile daha uzun süreli seviye tahminleri (üç günlük, aylık vb) yapılabilmektedir. Gradyen azalma eğitime algoritması kullanılmış ve algoritma parametrelerinin (eğitime oranı ve momentum katsayısı) yapay sinir ağıının performansına olan etkileri araştırılmıştır.

Taichung Limanında yapılan başka bir çalışmada (Tsai et. al., 1999), liman içinde yer alan üç adet ölçüm istasyonuna ait günlük veriler kullanılmıştır. Çalışmanın amacı iki istasyona ait dalga verileri yardımıyla üçüncü istasyona ait belirgin dalga yüksekliklerinin tahmini olup çalışmada ileri beslemeli yapay sinir ağı kullanılmıştır.

Deo ve Kumar (2000) tarafından Hindistan'ın Batı kıyısında yapılan çalışmada, ileri beslemeli denetimli yapay sinir ağıları, haftalık ortalama belirgin dalga yüksekliklerinin aylık ortalama dalga verilerinden tahmini amacıyla kullanılmıştır. Ağı eğitilmesinde üç farklı eğitime algoritmasından yararlanılmış, elde edilen sonuçlar istatistiksel model ve sayısal interpolasyon yoluyla tahmin edilen sonuçlarla karşılaştırılmış; yapay sinir ağlarının diğer yöntemlere kıyasla daha iyi sonuçlar verdiği ortaya konmuştur.

Karwar bölgesinde (Hindistan) yapılan bir çalışmada (Deo et. al., 2001), ileri beslemeli denetimli yapay sinir ağıları rüzgar verileri yardımıyla, derin deniz koşullarında, belirgin dalga yüksekliği ve dalga periyodu tahmininde kullanılmıştır. Rüzgar dalgalarının karmaşık yapısı, yüksek belirsizlikler içermesi ve dalga tahmininin çoğunlukla karmaşık modeller gerektirmesi çalışmanın temelini

oluşturmuştur. Çalışmada esas olarak belirgin dalga yüksekliği ve dalga periyodu (ağ çıktıları) üçer saatlik aralıklarla ölçülmüş meteorolojik veriler (rüzgar hızı, rüzgarın esme süresi ve kabarma mesafesi) kullanılarak tahmin edilmiştir. Elde edilen sonuçlar, yapay sinir ağlarının, deterministik modellerden farklı olarak, dalga parametrelerini yalnızca rüzgar hızlarına bağlı olarak tahmin edebildiğini göstermiştir.


Yapay sinir ağlarının kıyı mühendisliği uygulamalarında yönsel dağılım (directional wave spectrum) fonksiyonu da belirlenmiştir (Deo et al., 2002). Goa Bölgesinde (Hindistan) yapılan bu çalışmada, farklı yapılarda ileri beslemeli denetimli yapay sinir ağları ile dağılım parametresinin tahmini amaçlanmıştır; tasarlanan yapay sinir ağlarında, yönsel dağılım parametresi çıktı, belirgin dalga yüksekliği ve ortalama dalga periyodu gibi değişik parametreler ise girdileri oluşturmuştur. Test sonuçlarına bağlı olarak, özellikle belirgin dalga yüksekliği ve ortalama dalga periyodu ile yönsel dağılım parametresi arasında yüksek korelasyon gösteren bir ilişki ortaya konulmuş; doğrusal olmayan regresyon aynı oranda başarılı sonuçlar vermemiştir.

3. YAPAY ZEKA TEKNİKLERİ

İnsan düşüncesini ve davranışını taklit eden sistemler yanında akılcı düşünebilen ve davrananabilen sistemlerin geliştirilmesini amaç edinen çalışma alanlarının tümü Yapay Zeka (Artificial Intelligence) olarak tanımlanabilir (Russel and Norwig, 1995). 1950’li yıllarda başladığı kabul edilen ve nöroloji, psikoloji, mühendislik bilimleri gibi değişik disiplinleri kapsayan yapay zeka çalışmaları (Simon, 1995; Schalkoff, 1990) bilgisayar teknolojisindeki gelişmelere bağlı olarak hız kazanmış, yöntemsel ve kavramsal gelişimi sürdüren yeni bir alan olarak değerlendirilebilir. Yapay zeka, uygulama alanlarına bağlı olarak değişik yapay zeka tekniklerinin ayrı ayrı veya kombine bir şekilde kullanılmasını kapsamaktadır ve yapay sinir ağları (artificial neural networks), bulanık mantık (fuzzy logic), genetik algoritmalar (genetic algorithms) mühendislik problemlerinin çözümünde yaygın olarak kullanılan yapay zeka uygulamalarını oluşturmaktadır.

3.1. Yapay Sinir Ağları

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, 1000-10000 arasında değişen başka hücrelerle karşılıklı ilişki içerisinde. Bir sinir hücresinin temel elemanları hücre gövdesi, dendrit ve akson’dur (Harvey, 1994). Sinir hücresine (Şekil 3.1.a) diğer sinir hücrelerinden gelen uyarımlar, dendritler aracılığıyla hücre gövdesine taşınır ve hücre içi aktivasyonun/kararlılık halinin bozulmasıyla oluşan bir kimyasal süreç içerisinde diğer hücrelere 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 hücrelere dendritler aracılığıyla geçmesini sağlayan elemanlardır. Sinaptik boşluğa, “sinaptik kesecikler” tarafından sağlanan nöro-iletken maddenin dolması uyarımların diğer hücrelere geçişini sağlar. Hücrelere gelen uyarımlarla uyumlu olarak hücreler arasındaki mevcut sinaptik ilişkilerin değişimi veya hücreler arasında yeni sinaptik ilişkilerin kurulması “öğrenme” sürecine karşılık gelir.



Şekil 3.1. Biyolojik ve yapay sinir hücresi


Yapay sinir ağları esas olarak biyolojik nöronların basitleştirilmiş bir şekilde matematiksel olarak modellenmesine dayanmaktadır (Kirkegaard and Rytter, 1993; Kröse and Van der Smagt, 1996). Biyolojik ve yapay sinir hücreleri arasındaki benzeşim (Şekil 3.1), hücreler arasındaki bağlantılar (hücreye gelen ve hücreden çıkan uyarımlar) akson ve dendritlere; ağırlık faktörleri (w_i) sinapslara ve sınır değerler (t_j) hücre içi kararlılık haline karşılık gelecek şekilde oluşturulmaktadır (Şekil 3.1.b): Yapay sinir hücresinde, ağırlık faktörünün etkisine bağlı olarak (w_1, w_2, w_n) hücreye gelen uyarımlar (x_1, x_i, x_n) hücre içi denge durumu veya sınır değeri (t_j) de dikkate alınarak doğrusal olmayan bir aktivasyon fonksiyonu $f(.)$ yardımıyla çıktı şeklinde uyarımlara (y_j) dönüştürülür (Şekil 3.1.b). Yapay sinir hücrelerinin genellikle katmanlı bir yapı gösterecek biçimde birbirine bağlanmasıyla yapay sinir

ağları meydana getirilir ve yapay sinir hücreleri arasında kurulan bağlantılara ait ağırlık faktörlerinin, uyarımlarla uyumlu olacak şekilde değiştirilmesi benzer şekilde biyolojik “öğrenme” sürecine karşılık gelir.

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 (Kalagrou, 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 et al., 1997).

3.1.1. İleri beslemeli denetimli yapay sinir ağları

Girdi, çıktı ve bir veya daha çok ara katmanlardan oluşan ileri beslemeli denetimli yapay sinir ağları, girdi ve çıktı katmanları arasında tek doğrultuda aktivasyon gösteren sinir ağlarıdır ve aynı katman üzerinde bulunan hücreler arasında da herhangi bir ilişki yoktur. Ara katmandaki hücre sayısını belirleyen farklı yaklaşımlar olmasına karşın (Walczak and Cerpa, 1999) genel olarak hücre sayısı deneme-yanılma yoluyla belirlenmektedir. Şekil 3.2’de tek ara katmanlı ileri beslemeli denetimli bir sinir ağı örnek olarak verilmiştir. Burada, yapay sinir ağının girdi vektörü $\mathbf{x}=(x_1, x_2, x_k)$, kullanılarak elde edilen ara katman çıktı vektörü $\mathbf{h}=(h_1, h_2, h_3, h_s)$ çıktı katmanında işlendikten sonra çıktı vektörüne $\mathbf{y}=(y_1, y_2, y_z)$ dönüştürülür ve gözönüne alınan tüm girdi vektörleri $\mathbf{X}=[\mathbf{x}(1), \dots, \mathbf{x}(N)]$ için çıktı vektörleri $\mathbf{Y}=[\mathbf{y}(1), \dots, \mathbf{y}(N)]$, N: girdi ve çıktı vektörlerinin sayısı olmak üzere aşağıdaki şekilde hesaplanır:



Şekil 3.2. İleri beslemeli denetimli yapay sinir ağı

$$Y = \varphi(W^y[\psi(W^h X + b^h)] + b^y) \quad (3.1)$$

Denklem (3.1)'de $\varphi(\cdot)$: çıktı katmanına ait hücreler için aktivasyon fonksiyonu, $\psi(\cdot)$: ara katmana ait hücreler için aktivasyon fonksiyonu, b^h : ara katmandaki hücrelere ait sınır değer vektörü, b^y : çıktı katmanındaki hücrelere ait sınır değer vektörü, W^y : ara katman ile çıktı katmanı arasındaki bağlantılar için ağırlık faktörleri, W^h : ara katman ile girdi katmanı arasındaki bağlantılar için ağırlık faktörleri olarak alınmış olup sözkonusu ağırlık faktörleri aşağıdaki şekillerde tanımlanmıştır (Şekil 3.2):

$$W^h = [w_{11}^h \dots w_{1i}^h \dots w_{ji}^h] \quad j = 1, \dots, s; \quad i = 1, \dots, k \quad (3.2)$$

$$W^y = [w_{11}^y \dots w_{1m}^y \dots w_{zm}^y] \quad \ell = 1, \dots, z; \quad m = 1, \dots, s \quad (3.3)$$

Yapay sinir ağları uygulamaları genellikle eğitime ve test olmak üzere iki aşamada oluşturulur. Eğitime aşaması, katmanlar arasındaki ağırlık faktörlerinin ve sınır değerlerin bir eğitime algoritması yardımıyla hata seviyesi kabul edilebilir bir düzeye gelinceye kadar iteratif olarak düzeltilmesinden meydana gelir; ağırlık

faktörlerindeki değişim, öğrenme olarak da tanımlanabilir. Test aşamasında ise eğitime aşamasında kullanılmayan girdi ve çıktı verileri kullanılarak ağırlık performansı ölçülür. Değişik eğitime algoritmaları olmakla birlikte momentum katsayılı gradyen azalma ve konjuge gradyen eğitime algoritmaları yaygın kullanılan eğitime algoritmalarına örnek olarak verilebilir (Svozil et al., 1997; Golden, 1996).

Momentum katsayılı gradyen azalma algoritması, performans indeksinin (hata fonksiyonunun) minimizasyonuna dayanır ve ağırlık faktörleri, performans indeksi gradyeninin negatif doğrultusunda hareket edilmesiyle iteratif olarak düzeltilir:

$$\mathbf{w}(k+1) = \mathbf{w}(k) - \eta \nabla J(\mathbf{w}) + \alpha \Delta \mathbf{w}(k-1) \quad (3.4)$$

Burada, $\mathbf{w}$: vektörel olarak ağırlık faktörü, k : iterasyon sayısı, η : öğrenme oranı, α : momentum katsayısı ve $\nabla J(\mathbf{w})$: performans indeksinin gradyenidir. Performans indeksinin gradyeni ise ∇E : karesel hata fonksiyonunun gradyeni, N : girdi ve çıktı vektörlerinin sayısı ve z : çıktı katmanındaki hücre sayısı olmak üzere vektörel olarak Şekil 3.2’de verilen yapay sinir ağı için aşağıdaki şekillerde ifade edilir:

$$\nabla J(\mathbf{w}) = \frac{1}{zN} \sum_{n=1}^N \nabla E(\mathbf{w}, n) \quad (3.5)$$

$$\nabla E(\mathbf{w}, n) = \left[\frac{\partial E}{\partial \mathbf{w}_{1l}^h} \dots \frac{\partial E}{\partial \mathbf{w}_{ji}^h} \frac{\partial E}{\partial \mathbf{w}_{1l}^y} \dots \frac{\partial E}{\partial \mathbf{w}_{tm}^y} \right] \quad (3.6)$$

Öğrenme oranı ve momentum katsayısının seçilmesinde değişik yaklaşımlar olmasına karşın (Basheer and Hajmeer, 2000) bu katsayılar, genellikle 0-1 arasında değerler alacak şekilde deneme-yanılma yoluyla seçilmektedir.

Momentum katsayılı gradyen azalma algoritması ile birlikte konjuge gradyen eğitime algoritması gelişmiş eğitime algoritmalarından biridir; ağırlık faktörlerinin, konjuge gradyen eğitime algoritması kullanılarak düzeltilmesi halinde ise hareket doğrultusu,

daha önceki iterasyona ait hareket doğrultusu ile kombine olacak şekilde düzenlenir ve gradyen azalma algoritmasında olduğu gibi başlangıç doğrultusu performans indeksi gradyeninin negatif doğrultusu ($P_0 = -g_0$) olarak alınır:

$$w(k+1) = w(k) + \eta_k P_k \quad (3.7)$$

$$P_k = -g_k + \beta_k P_{k-1} \quad (3.8)$$

$$\beta_k = \frac{g_k g_k^T}{g_{k-1} g_{k-1}^T} \quad (3.9)$$


Burada, η_k : k'inci iterasyondaki öğrenme oranı ve β_k : Fletcher-Reeves faktörü olarak adlandırılabilir (De Gersem and Hameyer, 2001).

3.1.2. Geri beslemeli denetimli yapay sinir ağları

Geri beslemeli yapay sinir ağları, bir veya daha çok hücreye ait çıktılarının aynı katman içinde veya daha önceki katmanlarla kısmi olarak veya tamamen girdi şeklinde bağlanması yoluyla oluşturulan sinir ağlarıdır. Geri beslemeli ağlar, meydana getirilen geri beslemelerin tipine göre farklılıklar gösterir (Patterson, 1996; Principe et al., 2000) ve statik bir yapı gösteren ileri beslemeli denetimli yapay sinir ağlarından bu dinamik özelliği ile ayrılır.

Geri beslemeli sinir ağlarının en çok kullanılan tiplerinden biri Elman geri beslemeli sinir ağıdır (Şekil 3.3) ve bu tip ağlarda geri besleme ara katmanda yer alan hücrelere ait çıktılarının bir geri besleme katmanına (context layer) iletilmesiyle oluşturulur (Elman, 1990); geri besleme katmanının ileri beslemeli sinir ağlarının sahip olduğu “uzun süreli bellek”e ilave olarak “kısa süreli bellek” işlevi gördüğü söylenebilir (Tsoukalas and Uhrig, 1997). Bu nedenle, Elman tipi geri beslemeli sinir ağı özellikle zaman serileri gibi stokastik süreçlerin modellenmesinde kullanılmaktadır.

Elman tipi sinir ağlarında, eğitime aşamasında geri besleme katmanı ile girdi katmanı arasındaki ağırlık faktörleri ihmal edildiğinden ileri beslemeli denetimli sinir ağlarında kullanılan eğitime algoritmaları bu tip ağlarda da kullanılır.



Şekil 3.3. Elman tipi yapay sinir ağı

3.2. Bulanık Mantık

Bulanık mantık, esas olarak “bulanık küme teorisine” dayanan bir yapay zeka tekniğidir ve en geniş anlamda, değişik tanımlama olanakları olmasına karşın, bulanık küme teorisi ile eşanlamlı olarak da kullanılabilen matematiksel bir kavramlar ve ilkeler bütünü olarak görülebilir (Zadeh, 1999; Zadeh, 1997). Bulanık mantık, 1970’li yılların ortalarından itibaren birçok mühendislik dalında modelleme ve kontrol gibi değişik şekillerde yaygın bir kullanım göstermektedir (Ross, 1995).

Bulanık mantık yardımıyla bir sistemin modellenmesinde kullanılan bulanık sistemlerin veya bulanık modellerin klasik modelleme yöntemlerinden en büyük farkı belirsizlikleri değerlendirme biçimidir. Klasik yöntemlerde belirsizlikler istenmeyen veya azaltılması gereken durumlardır ve daha ayrıntılı modellemeler

yapılarak belirsizliklerin azaltılması ya da yüksek kesinlikli çözümlere gidilmesi mümkündür. Ancak, bu durum, hem zaman hem de maliyet açısından ekonomik olmayacağı gibi daha karmaşık modellerin ortaya çıkmasına neden olabilmektedir. İstatistiksel yöntemler ise, belirsizliklerin gözönüne alınmasında belirsizliklerin rassal olması ve belirsizliği modelleyen olasılık dağılımlarını ve parametrelerini belirleyecek yeterli istatistiki bilgi ve verinin mevcut olması halinde kullanılabilir. Bulanık sistemler ise doğal dilin (sözel değişkenlerin) içerdiği belirsizliklerden yararlanarak karmaşık sistemlerin modellemesini amaçlamaktadır. Başka bir deyişle bulanık sistemler, insanın belirsiz ortamlarda düşünebilme ve sonuç çıkarabilme yeteneğini taklit yoluyla, klasik modellemelerde kullanılmayan bilgi kaynaklarını kullanan sistemler olarak tanımlanabilir.

Bulanık sistemler belirsizlikleri işleyebilme yeteneğine rağmen yapay sinir ağları gibi öğrenebilen bir sistem değildir. Yapay sinir ağlarının, bulanık sistemlerle kombine edilmesi sonucunda elde edilen bulanık sinir ağları her iki tekniğin avantajlı yanlarını biraraya getirmeyi amaçlamaktadır. Bulanık sinir ağlarında sistemin girdi ve çıktıları bulanıklaştırılmakta ve yapay sinir hücrelerinin yerine bulanık sinir hücreleri kullanılmaktadır. Bulanıklaştırma işlemi, yapay sinir ağlarından farklı olarak ağ girdilerinin örneğin “sıcak” veya “soğuk” gibi sözel değişkenlerle tanımlanmasına olanak sağlarken; bulanık sinir hücreleri, işlevsel olarak aynı olmasına karşın, hücreye gelen uyarıların doğrusal olmayan bir fonksiyonla işlenmesi yerine bulanık operatörlerle işlenmesi nedeniyle yapay sinir hücrelerinden ayrılmaktadır. Bulanık mantık ilkelerinin bu yolla yapay sinir ağlarına eklenmesi belirsizlikleri işleyebilen ve aynı zamanda yapay sinir ağları gibi genelleştirebilen bir sistemin oluşturulmasını sağlamaktadır.

3.2.1. Bulanık mantık sistemleri

Bulanık mantık sistemleri, bir sistemi bulanık kural veya kurallar yardımıyla modelleyen sistemler olarak tanımlanır ve bu nedenle bulanık kural tabanlı sistemler olarak da adlandırılabilir (fuzzy rule-based systems). Bulanık kurallar, sistemin girdi ve çıktıları arasındaki ilişkiyi sözel değişkenlere bağlı olarak ve genellikle EĞER-

İSE şeklinde ortaya koyan ifadelerdir. Uzman bilgisini temsil eden bulanık kuralların EĞER ile İSE arasındaki kısmı sistemin girdileri; İSE'den sonraki kısmı ise sistemin çıktılarına karşılık gelmektedir. Bulanık bir kural ($\tilde{R}$), $\tilde{x}$: sözel değişken, $\tilde{y}$: sözel değişken, A: $\tilde{x}$ için bulanık alt küme , B: $\tilde{y}$ için bulanık alt küme olmak üzere aşağıdaki şekilde ifade edilebilir:

$$\tilde{R} : EĞER \quad \tilde{x} \text{ A } İSE \quad \tilde{y} \text{ B } dir.$$

Bulanık sistemler, bulanıklaştırma (fuzzification), bulanık kural tabanı (fuzzy rule base), bulanık genelleme (aggregation) ve durulaştırma (defuzzification) aşamalarından oluşan bulanık algoritmalar kapsamında oluşturulurlar.

3.2.1.1. Bulanıklaştırma

Bulanık sistemlerde, sözel değişkenlerin tipik değerleri (primary values) bulanık alt kümelerle temsil edilir ve her alt küme bir üyelik fonksiyonu ile ifade edilir: örneğin, elemanları x olan evrensel bir X kümesinin A bulanık alt kümesine aitliği üyelik fonksiyonları (membership function) ile belirlenir ve $\tilde{\mu}_A(x)$: üyelik fonksiyonu olmak üzere aşağıdaki şekilde ifade edilir:

$$\tilde{\mu}_A(x) : X \rightarrow [0,1] \quad (3.10)$$

Üyelik fonksiyonun değeri, x için A bulanık alt kümesine aitlik derecesini (membership degree) verir ve böylece bulanık kümeler yardımıyla, klasik küme teorisinin aksine, kısmi üyelik dereceleri tanımlanabilmektedir. Üyelik fonksiyonları olarak genellikle üçgen ve trapez fonksiyonlarla birlikte S tipi fonksiyonlar (Tsoukalas and Uhrig, 1997) kullanılmaktadır. Üçgen ($\tilde{\mu}_{üçgen}$) ve S tipi ($\tilde{\mu}_{S tipi}$) üyelik fonksiyonları, $\tilde{\alpha}$, $\tilde{\beta}$ ve $\tilde{\gamma}$ değerleri fonksiyon parametreleri olmak üzere sırasıyla aşağıdaki şekillerde verilebilir:

$$\tilde{\mu}_{uçgen}(x; \tilde{\alpha}, \tilde{\beta}, \tilde{\gamma}) = 0 \quad x > \tilde{\gamma}, x < \tilde{\alpha} \quad (3.11)$$

$$\tilde{\mu}_{uçgen}(x; \tilde{\alpha}, \tilde{\beta}, \tilde{\gamma}) = \frac{(x - \tilde{\alpha})}{(\tilde{\beta} - \tilde{\alpha})} \quad \tilde{\alpha} \leq x \leq \tilde{\beta} \quad (3.12)$$

$$\tilde{\mu}_{uçgen}(x; \tilde{\alpha}, \tilde{\beta}, \tilde{\gamma}) = \frac{(\tilde{\gamma} - x)}{(\tilde{\gamma} - \tilde{\beta})} \quad \tilde{\beta} \leq x \leq \tilde{\gamma} \quad (3.13)$$

$$\tilde{\mu}_{Stipi}(x; \tilde{\alpha}, \tilde{\beta}, \tilde{\gamma}) = 0 \quad x \leq \tilde{\alpha} \quad (3.14)$$

$$\tilde{\mu}_{Stipi}(x; \tilde{\alpha}, \tilde{\beta}, \tilde{\gamma}) = 2\left(\frac{x - \tilde{\alpha}}{\tilde{\gamma} - \tilde{\alpha}}\right)^2 \quad \tilde{\alpha} \leq x \leq \tilde{\beta} \quad (3.15)$$

$$\tilde{\mu}_{Stipi}(x; \tilde{\alpha}, \tilde{\beta}, \tilde{\gamma}) = 1 - 2\left(\frac{x - \tilde{\gamma}}{\tilde{\gamma} - \tilde{\alpha}}\right)^2 \quad \tilde{\beta} \leq x \leq \tilde{\gamma} \quad (3.16)$$

$$\tilde{\mu}_{Stipi}(x; \tilde{\alpha}, \tilde{\beta}, \tilde{\gamma}) = 1 \quad x \geq \tilde{\gamma} \quad (3.17)$$

3.2.1.2. Bulanık kural tabanı ve bulanık genelleme

Bulanık bir sistem çoğunlukla birçok kuralı içeren bir kural tabanına sahiptir ve herbiri ayrı bir bulanık ilişkiyi temsil eden kurallar, $x \in X \subset \mathfrak{R}$, $y \in Y \subset \mathfrak{R}$, $A_i \in A$, $B_i \in B$, $\tilde{\mu}_A(x): X \rightarrow [0,1]$ ve $\tilde{\mu}_B(y): Y \rightarrow [0,1]$ koşullarında ve X, Y, A ve B evrensel kümeler olmak üzere aşağıdaki şekilde yeniden yazılabilir:

$$\tilde{R}_i: EĞER \tilde{x} A_i İSE \tilde{y} B_i \text{ dir} \quad i = 1, 2, 3, \dots, K \quad (3.18)$$

Sistem içinde yer alan bulanık kuralların tümü ise bulanık kural tabanını ($\tilde{R}_b$) meydana getirir:

$$\tilde{R}_b = \{ \tilde{R}_i | i = 1, 2, 3, \dots, K \} \quad (3.19)$$

Bulanık kuralın ilk kısmında yer alan sözel değişken sayısının birden fazla olması durumunda her sözel değişkene ait ifade VE ya da VEYA operatörleri kullanılarak birbirine bağlanır; aynı operatörler kuralları birbirine bağlamakta da kullanılan operatörlerdir.

Kural tabanı içinde yer alan herhangi bir kural için, değişkenler arasındaki bulanık ilişki $\tilde{R}_i(x, y)$ analitik olarak aşağıdaki şekilde ifade edilebilir:

$$\tilde{R}_i(x, y) = \int_{(x,y)} \tilde{\mu}_{R_i}(x, y) / (x, y) \quad (3.20)$$

Burada, $\tilde{\mu}_{R_i}(x, y)$: sözel değişkenler arasındaki bulanık ilişkinin (implication relation) üyelik fonksiyonu olarak tanımlanabilir ve kesikli değişkenler için aşağıdaki şekilde yeniden yazılabilir:

$$\tilde{R}_i(x, y) = \sum_{(x,y)} \tilde{\mu}_{R_i}(x, y) / (x, y) \quad (3.21)$$

(3.20) ve (3.21) nolu ifadelerde ($\int$) integral ve ($\sum$) toplam işaretleri notasyonel olarak bulanık kümenin bütün değerlerini veya birleşimini (union) gösterirken, (/) bölüm işareti üyelik derecelerini küme elemanlarından (x,y) ayırmak için kullanılır.

Bulanık ilişkinin (implication relation) üyelik fonksiyonunun hesaplanmasında değişik bulanık ilişki operatörlerinden (fuzzy implication operator) yararlanılır (Ross, 1995). Bunlara örnek olarak Zadeh ve Larsen bulanık ilişki operatörleri (Tsoukalas and Uhrig, 1997) verilebilir ve bu operatörler maksimum ($\vee$), minimum ($\wedge$) ve cebirsel çarpım ($\cdot$) bulanık işlem operatörlerine bağlı olarak sırasıyla aşağıdaki şekillerde ifade edilebilir:

$$\tilde{\mu}_{R_i}(x, y) = (\tilde{\mu}_{A_i}(x) \wedge \tilde{\mu}_{B_i}(y)) \vee (1 - \tilde{\mu}_{A_i}(x)) \quad (3.22)$$

$$\tilde{\mu}_{R_i}(x, y) = \tilde{\mu}_{A_i}(x) \cdot \tilde{\mu}_{B_i}(y) \quad (3.23)$$

Bulanık genelleme, kural tabanında yer alan her kurala ait bulanık kümelerden yararlanılarak sisteme ait bulanık ilişkinin genelleştirilmesidir ve $\tilde{R}_i$: genelleştirilmiş bulanık ilişki olmak üzere aşağıdaki şekilde verilebilir:

$$\tilde{R} = \bigvee_{i=1}^K \tilde{R}_i \quad (3.24)$$

Sözel değişkenler arasındaki ilişki genelleştirilmiş bulanık ilişkiye bağlı olarak ve maksimum-minimum operatörü ($\circ$) kullanılarak tanımlanabilir:

$$\tilde{y} = \tilde{x} \circ \tilde{R} \quad (3.25)$$

Böylece bulanık sistemin girdisine ait sözel değişkenin bilinen ve farklı bir üyelik fonksiyonu (bulanık alt küme) ile tanımlanması halinde maksimum-minimum operatörü yardımıyla sistemin çıktısına ait üyelik fonksiyonu (bulanık alt küme) belirlenebilir.

3.2.1.3. Durulaştırma

Bulanık genelleme yoluyla elde edilen bulanık alt kümeler, uygulamalarda çoğunlukla durulaştırma yoluyla kesin değerlere dönüştürülür. Durulaştırma amacıyla kullanılan yöntemlere örnek olarak maksimum üyelik, ağırlık merkezi, ağırlıklı ortalama yöntemleri verilebilir (Ross, 1995). Ağırlık merkezi yönteminde, bulanık sisteme ait çıktının kesin değeri (y') çıktıya ait bulanık alt kümenin altında kalan alanın ağırlık merkezinin y düzlemi üzerindeki koordinatı olup $\tilde{\mu}_y$: çıktıya ait üyelik fonksiyonu olmak üzere aşağıdaki şekilde hesaplanabilir:

$$y' = \frac{\int \tilde{\mu}_y(y) y dy}{\int \tilde{\mu}_y(y) dy} \quad (3.26)$$


Bulanık çıktının kesikli bir değişken olarak tanımlanması halinde ise (3.26) nolu ifade $\tilde{N}$: bulanık alt kümedeki eleman sayısı olmak üzere aşağıdaki şekilde yazılabilir:

$$y' = \frac{\sum_{i=1}^{\tilde{N}} \mu_y(y_i) y_i}{\sum_{i=1}^{\tilde{N}} \mu_y(y_i)} \quad (3.27)$$


3.2.2. Bulanık sinir ağıları

Bulanık sinir ağıları, bulanık mantık ile desteklenmiş ya da bulanıklaştırılmış ileri beslemeli denetimli yapay sinir ağıları olarak adlandırılabilir. Bu yolla yapay sinir ağlarının karmaşık sistemleri modelleyebilme yeteneğinin belirsizlikleri de işleyebilecek şekilde geliştirilmesi amaçlanmaktadır. Ancak, bu konuda yapılan çalışmalar dikkate alındığında, bulanık sinir ağlarının kesin bir şekilde belirlenmiş ağ tipini temsil etmediği söylenebilir; yapay sinir ağlarının girdi ve çıktılarının bulanıklaştırılması ya da bunlara ilave olarak sinir hücrelerinin de bulanıklaştırılması gibi değişik yapılar (Hancheng et. al., 2002; Belarbi et. al., 2000; Palacharla and Nelson, 1999; Kuo and Xue, 1999; Feuring and Lippe, 1999; Rajasekaran et. al., 1996; Dash et. al., 1995; Liang and Cheng, 2002; Östernak, 1999; Buckley and Hayashi, 1995; Ishibuchi et. al., 1995) bulanık sinir ağıları olarak tanımlanabilmektedir. Burada, bulanık sinir hücreleri ve bu tip hücrelerle oluşturulan yapay sinir ağıları temel alınacaktır.

Bulanık sinir hücreleri, daha önce bahsedilen sinir hücreleriyle temelde aynı yapıya sahip olan fakat bulanık girdileri, bulanık operatörler yardımıyla bulanık çıktılara dönüştüren sinir hücreleridir ve kullanılan aktivasyon fonksiyonlarına ve bulanık operatörlere bağlı olarak değişiklikler göstermektedir (Vlachos and Avaritsiotis, 1996; Yeh, 1999). $\tilde{T}$ norm ve $\tilde{S}$ norm bulanık operatörler (Bölüm 3.2.1.1) kullanılarak elde edilen VE (AND) ve VEYA (OR) bulanık sinir hücreleri (Şekil 3.4-3.5) bu tip hücrelere örnek olarak verilebilir (Kwan and Cai, 1994; Yang et. al., 2000). VE ve VEYA bulanık hücrelerine ait çıktılar, (0) indisi sınır değere ait girdi ve ağırlık faktörlerine karşılık gelmek üzere, matematiksel olarak sırasıyla aşağıdaki şekillerde tanımlanabilir:



Şekil 3.4. VE tipi bulanık sinir hücresi



Şekil 3.5. VEYA tipi bulanık sinir hücresi

$$y_j = \tilde{T}_{i=0}^n (x_i \tilde{S} w_i) \quad (3.28)$$

$$y_j = \tilde{S}_{i=0}^n (x_i \tilde{T} w_i) \quad (3.29)$$


Burada her iki hücre tipi için, $\tilde{T}$ norm (product) ve $\tilde{S}$ norm (probabilistic sum) operatörlerine bağlı olarak, aktivasyon fonksiyonları sırasıyla aşağıdaki şekillerde tanımlanabilir (Gupta and Qi, 1991):

$$x_i \tilde{S} w_i = x_i + w_i - x_i w_i \quad (3.30)$$

$$x_i \tilde{T} w_i = x_i \cdot w_i \quad (3.31)$$

Şekil 3.4'te verilen VE tipi bulanık sinir hücresine gelen uyarımlar, her biri farklı bir bulanık alt kümeyi (A_1, A_2, A_n) tanımlayan üyelik dereceleri (x_1, x_2, x_n) ile ağırlık faktörlerinin (w_1, w_2, w_n), $\tilde{S}$ norm operatörlerle (VEYA) işlenmesiyle elde edilir ve $\tilde{T}$ norm (VE) operatörlerle $y_j = (x_1 \text{VEYA} w_1) \text{VE} (x_2 \text{VEYA} w_2) \text{VE} \dots \text{VE} (x_n \text{VEYA} w_n)$ şeklinde başka bir alt kümeyi (B) temsil etmek üzere çıktılarına dönüştürülür. İşlevsel açıdan $\tilde{T}$ norm ve $\tilde{S}$ norm operatörler sırasıyla minimum ($\wedge$) ve maksimum ($\vee$) operatörler olup VE tipi bulanık sinir hücresinin bir “minimum-maksimum” bulanık ilişki operatörü gibi çalıştığı ve “EĞER/İSE” şeklinde tanımlanan bulanık bir kurala karşılık geldiği söylenebilir: EĞER $x_1 A_1 \text{VE} x_2 A_2 \text{VE} x_n A_n$ İSE $y_j B$ 'dir. Şekil 3.5'te verilen VEYA tipi bulanık sinir hücresi ise bulanık kuralları birbirine bağlayan bir “maksimum-minimum” operatörü olarak değerlendirilebilir ve hücrenin çıktısı $y_j = (x_1 \text{VE} w_1) \text{VEYA} (x_2 \text{VE} w_2) \text{VEYA} \dots \text{VEYA} (x_n \text{VE} w_n)$ şeklinde ifade edilir: VEYA tipi sinir hücresi, gelen uyarımların VE tipi bir hücreye ait çıktılar olması durumunda, esas olarak bulanık kuralları birbirine bağlayan bulanık genelleme operatörü ($\vee$) olarak çalışır.

Bulanık sinir ağı, her katman aynı tip sinir hücrelerini içerecek şekilde genellikle girdi, VE ya da VEYA şeklinde bulanık hücrelerden oluşan ara ve çıktı katmanlarından oluşurlar (Şekil 3.6) ve ileri beslemeli denetimli sinir ağı ile aynı yaklaşım içinde eğitilirler. İşlevsel olarak, VE katmanı bir kural tabanı; VEYA katmanı ise bulanık genelleme katmanı olarak kabul edilebilir. Bulanık sinir ağlarında, girdi ve çıktı değerleri bulanık değerlerdir, ancak problemin türüne bağlı ve ağın çıktılarının bir durulaştırma katmanı ile durulaştırılması gerekebilir.



Şekil 3.6. Bulanık sinir ağı

3.3. Genetik Algoritmalar

Genetik algoritmalar, sezgisel bir arama yöntemi olup ilk kez 1985 yılında Goldberg (1989) tarafından yapılan bir çalışmanın ardından, değişik alanlarda uygulanma olanağı bulmuştur. Genetik operatörler yardımıyla “doğal seçim” sürecinin bilgisayar ortamında benzeştirilmesini esas alan genetik algoritmaları diğer arama yöntemlerinden ayıran en önemli özellikler amaç fonksiyonunu kullanması dolayısıyla türev hesaplarına dayanmaması; tek noktada değil birçok noktada (bir

grup çözüm içinde) arama yapması; parametrelerin kodlanmış diziler halinde temsil edilmesi ve stokastik bir arama yöntemi olması şeklinde özetlenebilir (Goldberg, 1989; Rao, 1996). Bu özellikler de, genetik algoritmaların, özellikle klasik arama yöntemlerinin yetersiz kaldığı karmaşık çözüm uzayları ile karakterize edilen, optimizasyon problemlerine uygulanmasını elverişli kılmaktadır; genetik algoritmaların bu tip problemlerde, global optimum çözüme genellikle daha yüksek bir olasılıkla ulaşabildiği söylenebilir.

Genetik algoritmalar, problemin olası çözümlerini temsil eden bir başlangıç topluluğunun, genetik operatörler yardımıyla daha iyi çözümleri temsil edecek şekilde evrilmesini amaçlayan iteratif bir teknik olarak da tanımlanabilir. Başlangıç topluluğu genellikle rastgele oluşturulan dizilerden (string) veya kromozomlardan meydana gelir. Problemin değişken ya da değişkenleri dizilerde kodlanmış olarak taşınır. Başlangıç topluluğunu oluşturan dizi sayısı genel bir kural olmamakla birlikte genellikle 30-200 değerleri arasında alınabilmektedir (Caldas and Norford, 2002). Kodlama işlemi ikili düzende, gerçel sayı ve permütasyon kodlama gibi değişik biçimlerde yapılabilmektedir (Kaya, 2001). Seçilim (reproduction), çaprazlama (crossover) ve mutasyon (mutation) operatörleri genetik algoritmaların temel elemanlarını meydana getirmektedir. Genetik algoritmaların genel yapısı aşağıdaki şekilde özetlenebilir:

1. Adım: başlangıç topluluğunu üret
2. Adım: topluluk içindeki her birey için uygunluk değerlerini sapt
3. Adım: eğer (bitiş koşulu) ise dur; değilse (4)'e git
4. Adım : genetik operatörleri uygula
5. Adım: (4)'ten yeni topluluk üret
6. Adım: (2)'ye git

3.3.1. Seçilim

Seçilim, topluluğu oluşturan her dizinin uygunluk değerlerine (amaç fonksiyonu değerleri) bağlı olarak kopyalanması işlemidir; bu işlem “doğal seçilimin”

bilgisayar ortamındaki karşılığı olarak da görülebilir. Topluluğu oluşturan her dizi, problemin olası çözümlerinden birini temsil eder ve seçim operatörü en uygun çözümlerin daha sonraki çözümleri (yeni toplulukları) daha yüksek olasılıkla etkilemesini amaçlar. Uygunluk değerleri saptanan diziler, bir seçim mekanizması ile kopyalama işlemine uğratılırlar. Rulet çemberi, seçim mekanizması oluşturmanın en yaygın ve basit yollarından birini oluşturmaktadır (Goldberg, 1989).

Rulet çemberi, her aralığı topluluğu meydana getiren dizilerin seçilme olasılıklarına karşılık gelen bir mekanizma olup bu yöntemde, kopyalanacak diziler, çemberin dizi sayısı kadar çevrilmesi sonucunda saptanmaktadır. Çemberin her çevrimiyle rastgele üretilen sayının karşılık geldiği aralık, kopyalanacak diziye de karşılık gelmektedir.


3.3.2. Çaprazlama

Çaprazlama operatörü, seçim operatörüyle elde edilen dizilerden yeni diziler başka bir deyişle yeni çözümler üretilmesidir ve bu işlem iki aşamada gerçekleştirilir: mevcut dizilerin rasgele eşleştirilmesi ve eşleştirilen diziler arasında belirli kısımların karşılıklı değiştirilmesi. Çaprazlama operatörü, çaprazlama oranına bağlı olarak, tek noktalı, iki noktalı ve üniform çaprazlama gibi değişik biçimlerde uygulanabilmektedir. Çaprazlama oranı 0,6-0,9 arasında değerler alabilmektedir (Mohan, 1997). Tek noktalı bir çaprazlama örneği şematik olarak Şekil 3.7’de verilmiştir.

3.3.3. Mutasyon

Mutasyon, bir dizinin bir veya birkaç değerininin rasgele değişikliğe uğratılmasıdır ve bu işlem yardımıyla seçim ve çaprazlama sonrasında ortadan kalkan dizilerin taşıdığı bilgilerin tümüyle kaybolması önlenir. Mutasyon dizide ani bir değişikliğe karşılık gelir ve bu değişiklik mutasyona uğramış diziye bağlı olarak daha sonraki toplulukları etkiler. Mutasyon operatörü, genetik

algoritmelerde ikinci derecede rol oynar ve iteratif olarak elde edilecek dizilerin birbirine benzemesine engel olarak daha iyi çözümlere ulaşılabilmesini sağlar. Mutasyon operatörünün uygulanmasında, 0,01 ve 0,001 arasında değerler alabilen bir mutasyon oranı kullanılabilir (Jenkins, 1997).



Şekil 3.7. Çaprazlamanın şematik olarak gösterimi (Goldberg, 1989)

4. EKSİK DALGA ÖLÇÜMLERİNİN YAPAY SİNİR AĞLARI İLE TAHMİNİ

Bu tezde Mersin Yat Limanı ana dalgakıranının yapay zeka teknikleri ile ön tasarımı gerçekleştirilecektir. Mersin Yat Limanı ana dalgakıranının ön tasarım için gerekli olan yıllık en yüksek belirgin dalga yükseklikleri rüzgar verilerinden yararlanılarak tahmin edilmekle birlikte (Özhan., Ergin, Yalçiner, 1994) Alanya Deniz yöresinde yönsel dalga ölçerle kaydedilen 1995 yılına ait 12 aylık dalga ölçümlerinin de en yüksek değer dalga istatistiği için değerlendirilmesi gereklidir. Bu ölçümler işletim zorlukları nedeniyle kesintilidir ve bu halde en yüksek değer dalga istatistiği için değerlendirilmesi belirsizlikleri artıran bir faktör olacaktır. Eksik (ölçüm alınamayan) verilerin güvenilir bir yöntemle tamamlanması gereklidir. Bu amaçla, Alanya deniz yöresindeki eksik dalga ölçümlerinin yapay sinir ağları ile tahmini gerçekleştirilmiş ve Bölüm 5’de en yüksek dalga istatistiği açısından değerlendirilmiştir (Balas and Koç, 2002).

Dalga parametreleri, kıyı yapılarının gerek tasarım gerekse işletim aşamasında kullanılan en önemli verilerdir ve genellikle sayısal modeller veya deneysel eşitlikler yardımıyla rüzgar verilerine bağlı olarak tahmin edilmektedirler (SPM, 1984). Ancak, bu tür yöntemler, rüzgar-dalga etkileşiminin karmaşık yapısı ve fırtına özelliklerinin ayrıntılı analizini gerektirmesi nedeniyle önemli belirsizlikler içermektedir (WMO, 1988).

Yapay sinir ağları, son yıllarda, zaman serilerinin tahminine değişik araştırmacılar tarafından (Balkin and Ord, 2000; Oliveria et. al., 2000, Al-Saba and El-Amin, 1999) yaygın olarak uygulanmıştır. Özellikle rüzgar dalgalarının karmaşık yapısı gözönüne alındığında dalga parametrelerinin tahminine yapay sinir ağlarının doğrusal AR (Autoregressive Model) ve ARX (Autoregressive Models with Exogenous Inputs) istatistiksel modellerden daha uygun olduğu söylenebilir. Doğrusal olmayan NARMA (Nonlinear Autoregressive Moving Average Models) ve NAR (Nonlinear Autoregressive Models) gibi istatistiksel modeller ise uygulamadaki güçlükler nedeniyle (Zhang et. al., 2001) tercih edilmemektedir.

Yapay sinir ağıları, doğrusal olmayan istatistiksel modellerden farklı olarak, parametrik olmayan veri tabanlı modellerdir ve veri tabanının içerdiği doğrusal veya doğrusal olmayan ilişkiyi belirli kabuller yapılmaksızın modelleyebilmektedir.

Dalga parametrelerinin ölçülme işlemi pahalı ve zor olmasının yanında işletim sırasında ortaya çıkan değişik sorunlar nedeniyle sık sık kesintiye uğrayabilmektedir. Eksik verilerin tamamlanması, dalga ikliminin belirlenmesi dışında işletim gibi kısa vadeli amaçlar için de gerekli bir çalışmayı oluşturmaktadır. Bu çalışmada, yapay sinir ağıları, Alanya bölgesinde yapılan dalga ölçümleri sırasında (Özhan and Abdalla, 2000) ortaya çıkan eksik verilerin tamamlanması amacıyla kullanılmış; çalışmanın, dalga parametrelerinin tahmininde mevcut yöntemlere alternatif oluşturabilmesi amaçlanmıştır. Çalışmada, ileri beslemeli ve geri beslemeli denetimli yapay sinir ağlarından yararlanılmıştır. Elde edilen sonuçlara bağlı olarak, yapay sinir ağlarının performansı stokastik yöntemlerle karşılaştırılmıştır. Literatürdeki diğer çalışmalardan (Deo et. al., 2001) farklı olarak, tezde girdi olarak kullanılan rüzgar verileri ile tasarlanan tek bir yapay sinir ağından aynı anda üç dalga parametresi (belirgin dalga yüksekliği, periyodu ve yönü) tahmin edilmiştir.

4.1. Stokastik Modeller ve Yapay Sinir Ağları

Bir zaman serisinin, belli aralıklar için, ardışık değerleri arasında istatistiksel bir bağımlılık bulunması halinde zaman serisinin stokastik bir süreç meydana getirdiği düşünülür. Serinin ardışık değerleri arasındaki istatistiksel bağımlılığın ölçüsü otokorelasyon katsayı ile tanımlanır ve aralarında belirli bir zaman aralığı bulunan, n elemanlı bir örneğin meydana getirdiği seri $(x_1, x_2, x_i, \dots, x_n)$ için, k aralıklı otokorelasyon katsayısı (r_i) , otokovaryans fonksiyonuna (cov) bağlı olarak $r_k = cov(x_i, x_{i+k}) / \sigma_x^2$ şeklinde hesaplanabilir. Otokorelasyon katsayısı, serinin k aralıklı değerleri arasındaki korelasyonu (içsel bağımlılığı) ortaya koyar ve farklı k aralıkları için hesaplanan otokorelasyon katsayıları sürecin otokorelasyon fonksiyonunu (koreologram) meydana getirir.

Stokastik süreçlerin önemli özelliklerinden biri stasyonerliktir. Stasyoner bir süreçte, rassal değişkeninin olasılık yoğunluk fonksiyonunun, parametrelerinin ve otokorelasyon katsayılarının zamandan bağımsız olduğu kabul edilir. Bir zaman serisini meydana getiren rassal değişkenlerin olasılık yoğunluk fonksiyonunun zamandan bağımsız ve yalnızca zaman aralıklarına bağlı olarak tanımlanması halinde güçlü stasyonerlik (strictly stationary) sözkonusu iken; stokastik sürecin istatistik parametrelerinin (ortalama, standart sapma ve otokorelasyon katsayıları) zamandan bağımsız olarak verilmesi zayıf (weak) stasyonerliğe karşılık gelir (Box, and Jenkins, 1976): Stasyoner bir süreç sabit ortalama ve standart sapma değerleriyle tanımlanıp otokorelasyon fonksiyonu yalnızca zaman aralığına bağlı olarak verilirken stasyoner olmayan bir süreç (non-stationary process) bir eğilim (trend) içerdiğinden bu parametreler zamana bağlı olarak tanımlanırlar. Genellikle, stokastik süreçlerin zayıf stasyonerlik göstermesi yeterli görülür ve sürecin davranışı otokorelasyon fonksiyonu ile karakterize edilir. Otokorelasyon fonksiyonunun istatistiksel olarak sıfırdan anlamlı derecede farklı değerler alması ya da üssel olarak k-aralığı arttıkça sıfıra yaklaşmaması serinin ardışık değerleri arasında güçlü bir ilişkinin varlığını başka bir deyişle serinin bir eğilime sahip olduğunu gösterir. Stokastik sürecin eğilime sahip bir davranış göstermesi ise sürece ait değişkenlerin rassal bir nitelik göstermediğini ve istatistik parametrelerin zamana bağlı olarak değişimini ortaya koyar.

Stasyoner bir süreç ya da zaman serisi genel olarak otoregresif hareketli ortalama modellerle, ARMA (p,q), karakterize edilir ve burada, p: lineer otoregresif modelin mertebesi, q: hareketli ortalama modelin mertebesi olarak tanımlanabilir. ARMA (p,q) tipi bir modelde, ϕ ve θ : model parametreleri olmak üzere değişkenin t anındaki değeri (x_t) ile p kadar önceki değerleri arasındaki (x_{t-p}) ilişki bağımsız değişkenin t ve t-q anındaki değerleri de (a_t ve a_{t-q}) dikkate alınarak aşağıdaki şekilde ifade edilebilir (Hamilton, 1994):

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} + a_t \quad (4.1)$$

Gözönüne alınan bir zaman serisinin analizinde, uygun modelin belirlenmesinde seriye ait otokorelasyon fonksiyonundan (koreologram) ve kısmi otokorelasyon fonksiyonundan yararlanılır; serinin kısmi otokorelasyon fonksiyonu, modelin doğrusal otoregresif bileşeninin (AR) mertebesini (p); koreologramı ise modelin hareketli ortalama bileşeninin (MA) mertebesini (q) belirlemekte kullanılır.

Bir yapay sinir ağının girdi katmanı, çıktı katmanından geri besleme şeklinde sağlanan ilave girdi değerleri içermiyorsa bu tip sinir ağlarının, yapısal olarak, doğrusal olmayan bir AR modele karşılık gelebilir (Doffner, 1996). AR model, ARMA modelin yalnızca otoregresif bileşeninden meydana gelir ve matematiksel olarak aşağıdaki şekilde tanımlanabilir:

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + a_t \quad (4.2)$$


AR modellerin çok değişkenli olması halinde, ARX (Auto Regressive Models with Exogenous Inputs) modellerden yararlanılır ve bu tip modeller, y: ilave değişken, n: modelin derecesi ve b_k : model parametresi olmak üzere, aşağıdaki şekilde ifade edilebilir:

$$x_t = \sum_{i=1}^p \phi_i x_{t-i} + \sum_{k=1}^n b_k y_{t-n} + a_t \quad (4.3)$$

4.2. Dalga Parametrelerinin Tahmini

Deniz yapılarının tasarımındaki ilk aşama ilgili deniz yöresindeki dalga ölçümlerinin istatistiksel olarak değerlendirilmesi ve eksik verilerin güvenilir yöntemlerle tahmin edilmesidir. Bu çalışmada, Alanya deniz yöresinde ölçülen ve belirgin dalga yüksekliği (H_s), ortalama dalga periyodu (T) ve dalga yönü (WD) ölçümlerinin (Özhan and Abdalla, 2000) çeşitli nedenlerle kesintiye uğramasından kaynaklanan eksik verilerin ileri ve geri beslemeli yapay sinir ağları kullanılarak tahmini yapılmıştır. Dalga verileri, Alanya Bölgesinde 36° 32' 30" Kuzey ve 31° 58' 30" Doğu


koordinatlarında bulunan yönsel dalga ölçer tarafından (Şekil 4.1) 12 ay boyunca ikişer saatlik aralıklarla, kayıt süresi 30 dakika; örneklem aralığı 0,78125 saniye ve örneklem frekansı 1,28 Hz olmak üzere 100 m su derinliğinde ölçülmüştür. Dalga parametrelerinin ölçülme işlemi, 2 ile 20 saat arasında ve aralıklı olarak sürekli kesintilere uğramıştır: Bütün gözlem dönemi boyunca, iki saatlik sürekli kesinti aralıklı olarak toplam 137; maksimum kesinti süresi olan 20 saat ise toplam iki kez gözlenmiştir. Farklı kesinti sürelerine ait gözlenme sıklıkları Şekil 4.2’de özetlenmiştir.



Şekil 4.1. Yönsel dalga ölçerin konumu

Dünya literatüründeki bu konuda yapılan sayılı çalışmalarda (Bölüm 2) genel olarak statik bir yapıya sahip olan ileri beslemeli denetimli sinir ağları kullanılarak tek bir dalga parametresi tahmin edilmiştir. Bu çalışmada, eksi dalga verileri (belirgin dalga yüksekliği, periyodu ve yönü) dinamik bir yapı gösteren Elman tip yapay sinir (geri beslemeli yapay sinir ağı) kullanılarak aynı anda tahmin edilmiştir. Başka bir deyişle, yapay sinir ağları ile mevcut dalga verileri yardımıyla her üç dalga parametresi de aynı anda tahmin edilmiştir. Dalga parametrelerinin tahmini, ileri beslemeli denetimli yapay sinir ağları ve doğrusal istatistiksel modeller (AR ve ARX) kullanılarak da

yapılmıştır. Elde edilen sonuçlara bağlı olarak ileri ve geri beslemeli sinir ağlarının performansı değerlendirilmiş ayrıca yapay sinir ağıları doğrusal istatistiksel modellerle karşılaştırılmıştır.



Şekil 4.2. Alanya dalga ölçüm istasyonundaki eksik verilerin gözlenme sıklığı

Kullanılan tahmin modellerinin test edilme aşamasında istatistiksel parametreler olan mutlak ortalama hata (MH) ve determinasyon katsayısından (r) yararlanılmıştır:

$$MH = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (4.4)$$

$$r = 1 - \frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (4.5)$$

Burada, $\hat{x}_i$: tahmin edilen deęer ve $\bar{x}$: gerek verilere ait ortalama deęer olarak alınmıřtır.

Toplam lm sresince kaydedilen dalga verilerine (zhan and Abdalla, 2000) ait maksimum (max), ortalama (m), minumum (min) ve standart sapma (sd) deęerleri; belirgin dalga ykseklięi (H_{smax} ; H_{sm} ; H_{smin} ; H_{ssd}) iin sırasıyla 3,56; 0,554; 0,06; 0,421 m; dalga periyodu (T_{max} ; T_m ; T_{min} ; T_{sd}) iin sırasıyla 7,55; 4,194; 2,0; 0,804 sn ve dalga yn (WD_{max} ; WD_m ; WD_{min} ; WD_{sd}) iin sırasıyla 330°; 45,315°; 2,80°; 15,453 ° olarak saptanmıřtır.

Yapay sinir aęları uygulamalarında kullanılan genel yaklařım, mevcut veri tabanının eęitme ve test amacıyla iki kısıma ayrılmasıdır ve eęitme ařaması iin ayrılan veri toplam verinin yaklaşık % 65-80'i (Basheer and Hajmeer, 2000) kadar olmaktadır. Ancak, bu alıřmada srekli (kesintiye uęramadan) kaydedilebilen en uzun veri kmesi, yani aynı anda llen dalga ykseklięi, dalga periyodu ve dalga yn verilerinin sayısı 184 olup bu deęer toplam gzlem sayısının % 4'ne karřılık gelmektedir. Bu nedenle, en uzun gzlem sresine sahip altı adet veri grubunun ikisi eęitme ve doęrulama (validation); geri kalanları ise test amacıyla kullanılmıřtır. Yapay sinir aęlarının arakestirime ynelik alıřtıęı kabul edildięinden en geniř deęer aralıęına sahip veri kmesi aęın eęitilmesi iin ayrılmıřtır.

Yapay sinir aęlarının eęitilme ařamasında karřılařılan nemli sorunlardan biri, iterasyon sayısının ok byk deęerler alması halinde yapay sinir aęının genelleyebilme yeteneęinin (yeni verilere karřı sonu verebilme) azalmasıdır. Bu durumda, yapay sinir aęı tmyle eęitme ařamasında kullanılan veri tabanına baęlı hale gelmektedir. Bu alıřmada, eęitme amacıyla kullanılan veri kmesinin toplam veri kmesinin yaklaşık % 3'ne karřılık gelmesi iterasyon sayısının seilmesini nemli kılmıřtır ve bu nedenle, ortalama deęerler aısından tm gzlem sresini temsil ettięi kabul edilen ikinci bir veri kmesi doęrulama amacıyla seilmiř; eęitme ařamasında erken durma (early stopping method) ynteminden (Coulibaly et. al., 2000) yararlanılmıřtır. Bu yntem yardımıyla, eęitme ařamasında her iki veri

kümesine ait hata oranları aynı anda izlenmekte ve doğrulama kümesine ait hata oranının artışa geçtiği noktada iterasyon durdurulmaktadır. Eğitim, doğrulama ve test aşamasında kullanılan veri kümelerine ait istatistiksel bilgiler Çizelge 4.1’de özetlenmiştir.

Bu çalışmada, rüzgar verilerinin kullanılması da amaçlandığından Çizelge 4.1’de belirtilen dönemlere ait meteorolojik verilere ait maksimum, minimum, ortalama ve standart sapma değerleri sırasıyla, rüzgar hızı (U_{max} ; U_{min} ; U_m ; U_{sd}) ve rüzgar yönü için (UD_{ma} ; UD_{min} ; UD_m ; UD_{sd}) Çizelge 4.2.’de verilmiştir. Rüzgar hızı değerleri Hsu (1985) tarafından önerilen şekilde düzeltilmiştir.

Yapay sinir ağlarının zaman serilerinin tahminine yönelik uygulamalarında, girdi katmanında yer alacak değişkenlerin ve zaman aralığının belirlenmesinde genel bir kural bulunmamaktadır. Bu çalışmada, dalga parametrelerinin tahmini, AR ve ARX modelleri de dikkate alınarak, tek değişkenli ve çok değişkenli modelleme olmak üzere iki farklı aşamada gerçekleştirilmiş; bu aşamalarda kullanılan yapay sinir ağları da buna bağlı olarak, ileri beslemeli ve geri beslemeli ağlar şeklinde oluşturulmuştur. Her iki aşamada, girdi katmanına ait değişkenlerin ve zaman aralığının belirlenmesinde istatistiksel parametreler olan otokorelasyon (OKF), kısmi otokorelasyon ve çapraz korelasyon fonksiyonlarından yararlanılmıştır. Her iki aşamada da, AR ve ARX modellerin ve literatürden farklı olarak, dalga parametrelerinin tümü, yapay sinir ağlarının tek bir işletiminden aynı anda (çoklu parametre tahmini) elde edilmiştir.

Çizelge 4.1. Eğitime, doğrulama ve test aşamasında kullanılan dalga verilerine ait istatistiki bilgiler

Veri kümesi	Eğitime	Doğrulama	Test 1	Test 2	Test 3	Test 4
Dönem (saat)	[252-544]	[2422-2614]	[6818-7184]	[3478-3728]	[1634-1804]	[8414-8572]
Gözlem sayısı	147	97	184	126	86	80
$H_{s_{max}}$ (m)	3,560	3,250	1,630	0,860	2,330	2,160
$H_{s_{min}}$ (m)	0,220	0,120	0,230	0,080	0,350	0,090
H_{sm} (m)	1,308	0,563	0,668	0,369	0,962	0,699
H_{sd} (m)	0,824	0,773	0,334	0,205	0,520	0,613
H_s için değişim katsayısı	0,629	1,373	0,500	0,555	0,540	0,876
T_{max} (s)	7,550	6,900	5,970	5,710	6,780	6,150
T_{min} (s)	3,510	2,450	2,740	2,020	3,310	2,260
T_m (s)	5,340	3,813	4,465	3,792	4,942	3,889
T_{sd} (s)	0,949	1,028	0,691	0,914	0,836	1,085
T için değişim katsayısı	0,177	0,269	0,154	0,241	0,169	0,279
WD_{max} (°)	95,400	99,900	68,000	74,300	68,600	100,200
WD_{min} (°)	14,200	16,400	24,700	13,900	28,100	11,600
WD_m (°)	55,898	44,629	45,576	44,962	42,554	62,869
WD_{sd} (°)	15,064	13,640	8,299	12,561	8,949	20,811
WD için değişim katsayısı	0,269	0,305	0,182	0,279	0,210	0,331

Çizelge 4.2. Eğitim, doğrulama ve test aşamasında kullanılan rüzgar verilerine ait istatistik bilgiler

Veri kümesi	Eğitme	Doğrulama	Test 1	Test 2	Test 3	Test 4
Dönem (saat)	[252-544]	[2422-2614]	[6818-7184]	[3478-3728]	[1634-1804]	[8414-8572]
Gözlem sayısı	147	97	184	126	86	80
U_{max} (m/s)	11,289	8,297	7,433	5,959	10,015	6,514
U_{min} (m/s)	0,646	0,646	0,000	0,000	1,344	0,000
U_m (m/s)	4,066	3,448	3,371	3,072	3,886	2,887
U_{sd} (m/s)	2,229	1,562	1,444	1,620	1,561	1,313
UD_{max} (°)	330,000	270,000	360,000	250,000	250,000	250,000
UD_{min} (°)	50,000	50,000	161,978	0,000	50,000	0,000
UD_m (°)	113,741	131,752	61,380	178,062	142,417	131,807
UD_{sd} (°)	57,400	58,987	2,638	55,776	62,651	52,245

Ayrıca, tek değişkenli tahmin modelleri olarak kurulan yapay sinir ağlarında, dalga parametrelerinin herhangi bir andaki değeri daha önceki ardışık değer ya da değerlere bağlı olarak elde edilmiştir ve yapay sinir ağı, AR modele karşılık gelmektedir. Bu modeller için eğitim, doğrulama ve test veri kümelerini meydana getiren bütün seriler için korelogramlar ve kısmi otokorelasyon fonksiyonları belirlenmiştir. Otokorelasyon fonksiyonu, bir zaman serisinin ardışık değerleri arasındaki içsel bağımlılığın ölçüsü olup stokastik modellerin, hareketli ortalama bileşeninin mertebesi yanında stasyonerliğin de kontrol edilmesinde kullanılmaktadır; serilerin kısmi otokorelasyon fonksiyonları ise AR modellerin mertebesini belirlemektedir (Bayazıt, 1996).

Otokorelasyon katsayısı hesaplanırken değişkenin herhangi bir t anındaki değerleri ile belirli ve sabit bir $(t+k)$ zaman aralığında aldığı değerler farklı rassal değişkenler olarak kabul edilir ve bu değişkenler arasındaki korelasyon katsayısı gözönüne alınan zaman aralığına ait k aralıklı otokorelasyon katsayısına karşılık gelir. Otokorelasyon katsayısının artı değerler alması değişkenin aralarındaki zaman aralığı $(t+k)$ olan değerleri arasındaki ilişkinin pozitif yönlü; eksi değerler alması ise ilişkinin negatif yönlü olduğunu gösterir. Kısmi otokorelasyon katsayısı, sürece $(k-1)$ mertebesinde AR modeli uydurulduktan sonra sürecin geriye kalan kısmı için otokorelasyon katsayısı olarak tanımlanabilir ve $AR(p)$ modeline uyan bir süreçte $k > p$ için kısmi korelasyon katsayıları sıfır olur. AR modellerin mertebesinin belirlenmesinde, modelin parametre sayısının mümkün olduğunca küçük olmasına (parsimoni kuralı) dikkat edilmiştir.


Eğitme, doğrulama ve test veri kümeleri için dalga parametrelerinin meydana getirdiği bütün serilerin, genel olarak, koreolagramları serilerin stasyonier olmayan (non-stationary) bir davranışa sahip olduğunu; kısmi otokorelasyon fonksiyonları ise serilerin genel olarak $AR(1)$ modele uygun kabul edilebileceğini göstermiştir. Şekil 4.3-5'de eğitim veri kümesi için sırasıyla belirgin dalga yüksekliğine, dalga periyoduna ve yönüne ait koreolagramlar ve kısmi otokorelasyon fonksiyonları örnek olarak verilmiştir: Şekil 4.3'de görüldüğü gibi belirgin dalga yüksekliklerinin oluşturduğu stokastik sürece ait otokorelasyon katsayıları zaman aralığının artmasıyla istatistiksel olarak, % 5 anlamlılık seviyesinde, sıfırdan anlamlı derecede farklı değerler almıştır. Bu durum serinin ardışık değerleri arasında güçlü bir ilişkinin (korelasyonun) olduğunu başka bir deyişle serinin bir eğilime/stasyonier olmayan davranışa sahip olduğunu ortaya koymaktadır. Benzer davranışlar dalga periyodu ve dalga yönü değerleri için de gözlenmiş olup Şekil 4.4-5'de verilen dalga periyoduna ve yönüne ait otokorelasyon katsayılarının değerleri, değişkenin herhangi bir anda aldığı değerle uzun zaman aralıklarında aldığı değerler arasında yüksek bir korelasyona karşılık gelmektedir: Koreolagramlar dikkate alındığında, dalga periyodu ve dalga yükseklikleri arasında daha büyük bir benzerlik olmasına karşın (Şekil 4.3-4) dalga yönü değerleri için hesaplanan otokorelasyon katsayılarının, zaman aralığının 10 ve daha büyük olduğu durumlar için (Şekil 4.5) sıfır kabul

edilebileceği söylenebilir. Dalga parametrelerinin genellikle stasyonere bir süreç oluşturduğu (WMO, 1988) kabul edilmesine karşın gözönüne alınan bütün serilerde belirgin biçimde stasyonere olmayan davranışların gözlenmesinin nedeni veri kümelerine ait gözlem dönemlerinin (Çizelge 4.1) kısa olmasına bağlanabilir: Veri kümeleri seçilirken gözlemlerin yalnızca en uzun kesintisiz dönemlere ait olmasına dikkat edilmiştir ve örneğin eğitime veri kümesi için gözlem sayısı 147 olup bu değer yaklaşık 12 günlük bir dönemi kapsamaktadır. Bu nedenle, gözlem sürelerinin bir fırtına dönemine veya fırtına döneminin belirli aşamalarına karşılık geldiği, dolayısıyla gözönüne alınan dönemlerde bu fırtına dalgalarının sürecin davranışında belirleyici olduğu düşünülebilir. Stokastik süreçlerin stasyonere olmayan yapısı, sürecin modellenmesinde büyük önem kazanır: Doğrusal modeller (ARMA, AR ve ARX) sürecin stasyonere hale getirilmesini gerektirirken, yapay sinir ağlarının kullanılması halinde buna gerek duyulmaz.


İleri beslemeli (İBSA) ve Elman tipi (ETSA) denetimli tek değişkenli yapay sinir ağları ve AR modeller kısmi otokorelasyon katsayıları dikkate alınarak oluşturulmuş ve özellikleri Çizelge 4.3’de verilmiştir. Burada, t : dalga parametresine ait tahmin zamanını, $(t-1)$: tahmin zamanından bir önceki zamanı göstermektedir.

Çizelge 4. 3. Tek değişkenli yapay sinir ağları ve AR modeller


Model	Girdi	Çıktı
İBSA	$H_s(t-1)$ $T(t-1)$ $WD(t-1)$	$H_s(t)$ $T(t)$ $WD(t)$
ETSA	$H_s(t-1)$ $T(t-1)$ $WD(t-1)$	$H_s(t)$ $T(t)$ $WD(t)$
AR(1)	$H_s(t-1)$	$H_s(t)$
AR(1)	$T(t-1)$	$T(t)$



Şekil 4.3. Eğitim veri kümesine için belirgin dalga yüksekliği değerlerine ait otokorelasyon ve kısmi otokorelasyon fonksiyonları



Şekil 4.4. Eğitim veri kümesine için ortalama dalga periyodu değerlerine ait otokorelasyon ve kısmi otokorelasyon fonksiyonları



Şekil 4.5. Eğitim veri kümesine için dalga yönü değerlerine ait otokorelasyon ve kısmi otokorelasyon fonksiyonları

Girdi ve çıktı katmanları Çizelge 4.3’de tanımlanan ileri ve geri beslemeli yapay sinir ağlarının eğitime aşamasında, momentum katsayılı gradyan azalma (MGA) ve konjuge gradyan (KG) eğitim algoritmaları kullanılmıştır. Her iki ağ tipinin girdi değerleri 0,1 ile 0,9 değerleri arasında normalize edilmiş; ara katmanlarda sigmoid aktivasyon fonksiyonu, çıktı katmanlarında ise lineer aktivasyon fonksiyonları kullanılmıştır. Ağırlık faktörlerinin başlangıç değerleri, Nguyen-Widrow yöntemiyle (Kamarthi and Pittner, 1999) rassal seçilmiş olup öğrenme oranı ve momentum katsayısı deneme-yanılma yoluyla 0,1 seçilmiş; öğrenme oranı (η) için başlangıç değeri 0,01 olarak alınmıştır.

Eğitim aşamasında, karesel ortalama hata (KH), performans fonksiyonu olarak alınmış ve doğrulama veri kümesi için hata oranlarının artmaya başladığı noktalarda iterasyon durdurulmuştur. MGA eğitim algoritmasının kullanıldığı eğitim aşamasında doğrulama veri kümesi için hata oranında artış gözlenmemesine karşın eğitim işlemine iterasyon sayısının 10000 olduğu noktada son verilmiştir. Ara katmanlardaki hücre sayıları deneme-yanılma yoluyla belirlenmiş ve her iki ağ tipi için uygun ağ yapıları ve iterasyon sonuçları Çizelge 4.4’ de verilmiştir.

Çizelge 4.4. Tek değişkenli yapay sinir ağlarının yapısı ve iterasyon sonuçları

Ağın Tipi	Ağın Yapısı	Eğitme Algoritması	KH	İterasyon
ETSA	$x_3h_{15}y_3$	KG	0,00134	49
ETSA	$x_3h_{15}y_3$	MGA	0,00193	10 000
İBSA	$x_3h_{15}y_3$	KG	0,00130	34
İBSA	$x_3h_{15}y_3$	MGA	0,00144	10 000

AR(1) modeline ait parametreler, belirgin dalga yüksekliği ve dalga periyodu için ayrı ayrı en küçük kareler yöntemiyle iteratif olarak belirlenmiş ve iterasyon sonundaki karesel ortalama hata değerleri her iki parametre için sırasıyla 0,0022 ve 0,0030 olarak hesaplanmıştır. AR modeline ait hesaplamalar için stasyonerliğin sağlanması amacıyla bütün dalga verilerinin birinci mertebeden diferansiyeli alınmış ve seriler standart değişkenlere dönüştürülmüştür.

Eğitilen sinir ağlarının ve AR(1) modellerin performansı, kısa (iki saatlik) tahmin aralığı için, test veri kümeleri kullanılarak ve mutlak ortalama hata değerleri (MH) ile determinasyon katsayıları (r) hesaplanarak değerlendirilmiştir. Test aşamasına ait sonuçlar, KG eğitme algoritması ile eğitilen ağlar ve AR(1) modeller için Çizelge 4.5’de; MGA eğitme algoritması ile eğitilen ağlar için Çizelge 4.6’da özetlenmiştir. Modellerin performansını test etmek amacıyla kullanılan ve (4.5) nolu eşitlikle tanımlanan determinasyon katsayıları, gerçek verilere ait varyans değerleriyle normalize edilen karesel ortalama hatanın bir fonksiyonudur. Determinasyon katsayılarının bire yakın değerler aldığı modeller başarılı olmasına karşın determinasyon katsayılarının sıfıra yakın değerler alması (determinasyon katsayısı karesel hatanın bir fonksiyonu olduğu ve karesel hata büyük değerlere ulaştığı için) modelin başarısız olduğunu göstermektedir. Ancak, karesel hata $\sum_{i=1}^n (x_i - \hat{x}_i)^2$

değerlerinin gerçek verilere ait $\sum_{i=1}^n (x_i - \bar{x})^2$ varyans değerlerinden daha büyük

değerler aldığı durumlarda, determinasyon katsayıları sıfırdan küçük değerler de almıştır. Determinasyon katsayılarının sıfıra yakın veya negatif değerler aldığı tüm modeller aynı oranda başarısız kabul edilmiştir (Çizelge 4.5).

Çizelge 4.5. KG eğitme algoritması ile eğitilen tek değişkenli yapay sinir ağlarına ve AR modellere ait kısa tahmin aralıklı test sonuçları

Model	Parametre	Test 1		Test 2		Test 3		Test 4	
		MH	r	MH	r	MH	r	MH	r
ETSA	H _s	0,019	0,879	0,014	0,862	0,025	0,884	0,027	0,932
	T	0,028	0,848	0,033	0,888	0,033	0,850	0,036	0,920
	WD	0,016	-0,010	0,022	0,198	0,017	0,104	0,021	0,619
İBSA	H _s	0,021	0,847	0,026	0,474	0,029	0,874	0,037	0,891
	T	0,031	0,809	0,059	0,604	0,033	0,852	0,063	0,730
	WD	0,012	0,408	0,020	-0,267	0,021	0,465	0,022	0,473
AR (1)	H _s	0,021	0,155	0,009	0,234	0,030	-0,088	0,022	0,296
AR (1)	T	0,036	0,340	0,038	0,103	0,051	0,162	0,037	0,398

Çizelge 4.6. MGA eğitme algoritması ile eğitilen tek değişkenli yapay sinir ağlarına ait kısa tahmin aralıklı test sonuçları

Model	Parametre	Test 1		Test 2		Test 3		Test 4	
		MH	r	MH	r	MH	r	MH	r
ETSA	H _s	0,034	0,713	0,041	-0,022	0,041	0,813	0,042	0,844
	T	0,034	0,805	0,042	0,830	0,037	0,814	0,043	0,887
	WD	0,029	-1,774	0,039	-1,199	0,030	-1,67	0,035	0,0384
İBSA	H _s	0,027	0,766	0,048	-1,465	0,030	0,860	0,070	0,623
	T	0,031	0,805	0,067	0,425	0,034	0,847	0,077	0,587
	WD	0,014	0,118	0,031	-2,126	0,014	0,222	0,033	-0,190

Çizelge 4.5-6'da verilen sonuçlar determinasyon katsayılarına bağlı olarak karşılaştırıldığında, KG eğitme algoritması ile eğitilen ağların daha başarılı olduğu görülmektedir. Her iki ağ tipi için yaklaşık eşit kabul edilebilecek karesel hata oranlarına (Çizelge 4.4) KG eğitme algoritması ile çok daha hızlı ulaşılması, ağların performansını başka bir deyişle determinasyon katsayılarını artıran bir faktör olmuştur. Her iki algoritma arasındaki fark, en küçük ortalama değere sahip (2) nolu

test kümesi için belirgin dalga yüksekliklerinin tahmininde determinasyon katsayısının (Çizelge 4.5) KG için 0,862 değerini, MGA için -0,022 değerini (Çizelge 4.6) almasıyla gözlenmektedir. KG eğitme algoritmasının (Bölüm 3.1.1) daha hızlı sonuç vermesinin nedeni iteratif hareket doğrultularının MGA algoritmasındaki gibi birbirine dik (orthogonal) olmayıp birbiriyle kombine edilerek düzeltilmesidir.

Çizelge 4.5’de ETSA ve İBSA için test aşamasına ait sonuçlar karşılaştırıldığında ise ETSA ile yapılan tahminlerin daha yüksek determinasyon katsayılarına sahip olduğu görülmektedir ve bu durum bu tip sinir ağlarında geri besleme yoluyla oluşturulan ve “kısa süreli bellek” işlevi gören ilave katmanların katkısıyla açıklanabilir. ETSA ile yapılan tahminler gözönüne alındığında (4) nolu test kümesine ait determinasyon katsayılarının, belirgin dalga yüksekliği ve dalga periyodu için diğer test kümeleri için verilen değerlerden daha yüksek değerler aldığı söylenebilir. Bu sonuç, her iki dalga parametresi için hesaplanan değişim katsayıları gözönüne alındığında (Çizelge 4.1), doğrulama ile (4) nolu test kümelerinin istatistiksel açıdan belirgin biçimde birbirine daha yakın kümeler olması ile açıklanabilir ve diğer test kümeleri için de genel olarak aynı şekilde ifade edilebilir. Değişim katsayılarına bağlı olarak doğrulama kümesine daha yakın test kümelerinin daha yüksek determinasyon katsayılarına sahip olması, “erken durma yöntemi” ile yapılan eğitme işlemlerinde doğrulama veri kümelerinin ağların tahmin yeteneğinde daha belirleyici olduğunu düşündürmektedir.

Dalga yönü tahminleri, bütün test kümeleri için, düşük determinasyon katsayıları nedeniyle (Çizelge 4.5-6) başarılı bulunmamıştır: Çizelge 4.1’de görüldüğü gibi eğitme ve doğrulama veri kümeleri kısa sayılabilecek, yaklaşık 12 ve 8 günlük, gözlem dönemlerini kapsamakta ve bütün veri kümeleri için ortalama dalga yönü değerleri birbirine yakın değerler almaktadır. Bu gözlem dönemlerine ait dalga yönü değerlerinin, hakim rüzgar/dalga yönünün etkisinde fırtına dönemlerine karşılık geldiği, dolayısıyla diğer dalga parametrelerine göre daha yavaş değişimler (maksimum ve minimum değerler geniş bir aralık belirtmesine karşın) gösterdiği kabul edilebilir. Bu nedenle, yapay sinir ağlarının dalga yönü değerlerini diğer

parametrelerle birlikte işlemesine karşın başarılı bir şekilde genelleyemediği düşünülmektedir. Eğitim ve doğrulama aşamalarında daha uzun süreli gözlemlerin kullanılması halinde, bütün dalga parametreleri aynı anda tahmin edilmek üzere, dalga yönü değerlerinin de başarılı olarak tahmin edileceği söylenebilir.

Çizelge 4.5’de görüldüğü gibi bütün ağ tipleri ve eğitim algoritmaları için yapay sinir ağları, doğrusal modellerden daha yüksek determinasyon katsayıları vermiş olup elde edilen sonuçlar, karmaşık bir yapı gösteren dalga parametrelerinin tahmininde doğrusal modellerle doğrusal olmayan yapay sinir ağları arasındaki farkı ortaya koymaktadır: Yapay sinir ağları ve doğrusal modeller için iteratif olarak hesaplanan karesel ortalama hata değerleri (performans indeksi) birbirine yakın olmasına karşın doğrusal modellerin yeni veri kümelerini genelleyebilme yeteneğinin yapay sinir ağları kadar yüksek olmadığı gözlenmiştir.

Eğitilen ağlar ve AR(1) modeller daha uzun tahmin aralıkları için de test edilmiştir. Burada, iki saatlik tahmin aralığı yerine, test veri kümelerinin son 48 saatlik kısımları tahmin edilen değerlerin geri besleme yoluyla girdi katmanına iletilmesiyle sentetik olarak üretilmişlerdir. Bu aşamaya ait hata ve determinasyon katsayısı değerleri benzer şekilde Çizelge 4.7-4.8’de verilmiştir. Bütün test kümeleri için son 48 saatlik kısımların sentetik olarak üretilmesi, kısa aralıklı tahminler için Çizelge 4.5-6’da özetlenen sonuçlarla ağ tipleri ve eğitim algoritmaları açısından uyumludur. Özellikle (4) nolu test kümesine ait determinasyon katsayılarında diğer test kümelerine kıyasla daha yüksek oranlarda düşme gözlenmesine karşın Çizelge 4.7’de ETSA için verilen determinasyon katsayılarının kabul edilebilir seviyelerde olduğu görülmektedir. Kısa aralıklı ve uzun aralıklı tahminlerin karşılaştırılması tek ve çok değişkenli modellerle birlikte ilerdeki kısımlarda ayrıntılı olarak değerlendirilmiştir.

Çizelge 4.7. KG eğitme algoritması ile eğitilen tek değişkenli yapay sinir ağlarına ve AR modellere ait uzun tahmin aralıklı test sonuçları

Model	Parametre	Test 1		Test 2		Test 3		Test 4	
		MH	r	MH	r	MH	r	MH	r
ETSA	H _s	0,023	0,830	0,018	0,778	0,029	0,869	0,051	0,727
	T	0,030	0,828	0,035	0,868	0,035	0,846	0,066	0,631
	WD	0,018	-0,488	0,023	0,150	0,023	-0,911	0,034	-0,004
İBSA	H _s	0,021	0,848	0,027	0,435	0,043	0,763	0,129	-1,107
	T	0,039	0,662	0,066	0,536	0,065	0,412	0,124	-0,140
	WD	0,013	0,207	0,023	-0,420	0,017	-0,215	0,032	0,054
AR (1)	H _s	0,021	0,115	0,009	0,240	0,030	-0,114	0,025	0,110
AR (1)	T	0,038	0,258	0,038	0,087	0,051	0,140	0,040	0,296

Çizelge 4.8. MGA eğitme algoritması ile eğitilen tek değişkenli yapay sinir ağlarına ait uzun tahmin aralıklı test sonuçları

Model	Parametre	Test 1		Test 2		Test 3		Test 4	
		MH	r	MH	r	MH	r	MH	r
ETSA	H _s	0,014	0,578	0,052	-0,462	0,039	0,812	0,060	0,715
	T	0,037	0,757	0,047	0,785	0,037	0,813	0,077	0,573
	WD	0,029	-1,737	0,039	-1,229	0,032	-1,938	0,039	-0,094
İBSA	H _s	0,055	-0,554	0,090	-6,761	0,076	0,036	0,093	0,409
	T	0,040	0,659	0,084	0,180	0,050	0,691	0,093	0,494
	WD	0,014	0,109	0,037	-2,594	0,016	-0,025	0,038	-0,368


Bu çalışmanın ikinci aşamasında, dalga parametrelerinin Alanya meteoroloji istasyonuna ait rüzgar verileri (rüzgar hızı ve rüzgarın esme süresi) ile tahmini amaçlanmıştır. Yalnızca rüzgar verilerine bağlı olarak geliştirilen yapay sinir ağlarının kullanıldığı çalışmada (Deo et al., 2001) yüksek korelasyonlu sonuçlar gözlenmemiştir. Bu sebeple tezde geliştirilen tahmin modelleri, rüzgar ve dalga verilerinin birlikte kullanıldığı çok değişkenli modeller olarak tasarlanmış ve böylece dalga parametrelerinin tahmini, meteorolojik verilerle de desteklenmiştir.

Ağ yapılarının tasarlanmasında, dalga verileri en düşük oranda tutulmuş; rüzgar verilerinin hangi aralıklarda kullanılacağı ise dalga parameterleri ile rüzgar verileri arasındaki çapraz korelasyon fonksiyonlarına bağlı olarak belirlenmiştir. Çapraz korelasyon katsayıları iki farklı değişken arasında belirli ve sabit zaman aralıkları için hesaplanan otokorelasyon katsayıları olarak tanımlanabilir ve çapraz korelasyon katsayısının artı değerler alması değişkenlerin gözönüne alınan zaman aralığındaki değerleri arasındaki ilişkinin pozitif yönlü; eksi değerler alması ise ilişkinin negatif yönlü olduğunu gösterir. Ancak, otokorelasyon katsayılarından farklı olarak zaman aralığının artı ve eksi değerleri için simetrik bir yapı göstermez. Çapraz korelasyon fonksiyonları, tüm veri kümeleri için aynı dönemlere ait rüzgar verileri yardımıyla hesaplanmıştır.


Dalga parametreleri (belirgin dalga yüksekliği, dalga periyodu ve yönü) ile rüzgar verileri (rüzgar hızı ve yönü) arasındaki çapraz korelasyon ilişkisi, eğitme, doğrulama ve test kümelerinden oluşan bütün veri kümeleri için belirlenmiştir. Gözönüne alınan bütün veri kümeleri için belirgin dalga yükseklikleri ve dalga periyodları ile rüzgar hızları (U) arasında genellikle belirli oranlarda korelasyon (% 5 anlamlılık seviyesinde) gözlenmesine karşın bu dalga parametreleri ile rüzgar yönü (UD) arasında istatistiksel anlamda dikkate değer bir korelasyon gözlenmemiştir:

Eğitme veri kümesi için belirlenen çapraz korelasyon fonksiyonları diğer veri kümelerine kıyasla dalga parametreleri ile rüzgar verileri arasındaki ilişkinin daha yüksek korelasyon değerleriyle gözlemlendiği veriler olup bu veri kümesine ait çapraz korelasyon fonksiyonları, bütün dalga parameterleri için, Şekil 4.6-4.8'de örnek olarak verilmiştir. Çapraz korelasyon fonksiyonları, farklı seriler arasındaki nedensel ilişkiyi zaman aralıklarına bağlı olarak verir. Şekil 4.6.a'da, rüzgar yönleri ile belirgin dalga yükseklikleri arasındaki bir ilişkinin varlığı hipotezi, %5 anlamlılık seviyesi sınırları içinde çapraz korelasyon katsayısı sıfıra yakın değerler aldığından reddedilmiş ve iki değişken (rüzgar yönü ve belirgin dalga yüksekliği) arasında bir ilişkinin gözlenmediği sonucuna varılmıştır. Şekil 4.6.b'de ise korelasyon fonksiyonunun, bütün zaman aralıklarında sıfırdan anlamlı derecede farklı olduğu görülmüştür. Bu durumda, en yüksek çapraz korelasyon katsayısına zaman aralığının


($t-2$) değerinde ulaşılmakta ve herhangi bir t anındaki belirgin dalga yüksekliği değerleriyle, ($t-2$) zaman aralığındaki (iki zaman adımı öncesindeki) rüzgar hızları arasında yüksek bir korelasyon ilişkisinin varlığı gözlenmektedir. Bu noktadan itibaren zaman adımı arttıkça, korelasyon katsayılarının beklendiği şekilde simetrik olarak azaldığı görülmektedir: Gözönüne alınan bu dönem, rüzgar hızının maksimum ve ortalama değerler açısından en yüksek olduğu dönemdir (Çizelge 4.2). Burada, belirgin dalga yükseklikleri ile rüzgar hızları arasındaki istatistiksel ilişki anlamlı (korelasyon katsayısı %5 anlamlılık seviyesinin üzerinde) olduğundan, söz konusu dönemin bir fırtına dönemi olduğu sonucuna varılmıştır.



Şekil 4.6. Eğitime veri kümesi için belirgin dalga yüksekliği değerleriyle (H_s) rüzgar yönü (a) ve hızı (b) arasındaki çapraz korelasyon fonksiyonları



Şekil 4.7. Eğitim veri kümesi için ortalama dalga periyodu (T) değerleriyle rüzgar yönü (a) ve hızı (b) arasındaki çapraz korelasyon fonksiyonları



Şekil 4.8. Eğitim veri kümesi için dalga yönü (WD) değerleriyle rüzgar yönü arasındaki çapraz korelasyon fonksiyonları

Şekil 4.7’de verilen, dalga periyodu ile rüzgar yönü ve hızı arasındaki çapraz korelasyon fonksiyonları belirgin dalga yüksekliği için belirlenen çapraz korelasyon fonksiyonları ile benzerlik göstermektedir. Dalga periyodunun rüzgar yönü ile arasında anlamlı bir ilişki (Şekil 4.7.a) olmamasına karşın; rüzgar hızı ile arasında (korelasyon katsayısı %5 anlamlılık seviyesinin üzerinde olduğundan) anlamlı bir ilişki olduğu (Şekil 4.7.b) söylenebilir. Belirgin dalga yüksekliği ile dalga periyodu değerlerine ait çapraz korelasyon fonksiyonlarının benzer eğilimler göstermesi beklenen bir durumdur. Dalga yönü ile rüzgar yönü arasında ise, zaman aralığının ($t-6$) ile ($t+4$) arasındaki değerlerinde anlamlı bir ilişki gözlenmesine karşın (Şekil 4.8), korelasyon katsayıları düşük değerler almıştır. Buna rağmen, sözkonusu istatistiksel ilişki, bütün veri dönemleri için saptanmış en yüksek ilişkiye karşılık gelmektedir. Aynı dönem için ortalama dalga (Çizelge 4.1) ve rüzgar yönleri (Çizelge 4.2) sırasıyla, yaklaşık 56° ve 114° olup büyük farklılıklar göstermektedir. Bu farklılık bütün veri kümelerine ait dönemler için de geçerlidir ve bu durum bölgedeki dalga hareketlerinin tümüyle yersel rüzgarların etkisinde olmadığını göstermektedir.

Yukarıda tanımlanan çapraz korelasyon fonksiyonlarının sözkonusu bölgeye ait rüzgar-dalga ilişkisinin genel eğilimini yansıttığı söylenebilir, ancak rüzgar-dalga ilişkisi sürekli değişim gösterebilen karmaşık bir yapıya sahiptir. Bu sebeple, çok değişkenli tahmin modelleri içerisinde rüzgar yönleri alınmamış; ilave değişkenler olarak yalnızca rüzgar hızları kullanılmıştır. Ancak, tahmin modelleri içerisinde yer alacak ilave değişkenlerin mertebesinin (zaman aralıklarının) belirlenmesinde tümüyle eğitime veri kümesi için verilen çapraz korelasyon fonksiyonuna (Çizelge 4.6.b) bağlı kalınmamıştır. Rüzgar hızı için uygun aralık değerlerini de içeren ağ tipleri, farklı ağ yapılarının denenmesi sonucunda bulunmuştur ve seçilen ağ tipleri ve bunlara karşılık gelen ARX modeller Çizelge 4.9.’da verilmiştir. ARX modellerin mertebesi, karşılaştırma amacıyla, yapay sinir ağlarına bağlı olarak belirlenmiştir. Bu çalışmada, çok değişkenli doğrusal model, p : esas değişkenin (dalga parametresi) mertebesi ve q : ilave değişkenin (rüzgar hızı) mertebesi olmak üzere $ARX(p,q)$ olarak verilmiştir.

Çizelge 4. 9. Çok değişkenli yapay sinir ağları ve ARX modeller

Model	Girdi	Çıktı
İBSA	$H_s(t-1)$ $T(t-1)$ $WD(t-1)$ $U(t)$ $U(t-1)$ $U(t-2)$ $U(t-3)$ $U(t-4)$ $U(t-5)$ $U(t-6)$ $U(t-7)$ $U(t-8)$	$H_s(t)$ $T(t)$ $WD(t)$
ETSA	$H_s(t-1)$ $T(t-1)$ $WD(t-1)$ $U(t)$ $U(t-1)$ $U(t-2)$ $U(t-3)$ $U(t-4)$ $U(t-5)$ $U(t-6)$ $U(t-7)$ $U(t-8)$	$H_s(t)$ $T(t)$ $WD(t)$
ARX(1,9)	$H_s(t-1)$ $U(t)$ $U(t-1)$ $U(t-2)$ $U(t-3)$ $U(t-4)$ $U(t-5)$ $U(t-6)$ $U(t-7)$ $U(t-8)$	$H_s(t)$
ARX(1,9)	$T(t-1)$ $U(t)$ $U(t-1)$ $U(t-2)$ $U(t-3)$ $U(t-4)$ $U(t-5)$ $U(t-6)$ $U(t-7)$ $U(t-8)$	$T(t)$

Eğitme aşamasında, öğrenme oranı ve momentum katsayıları 0,2 olarak alınmış olup uygun ağ tipleri ve iterasyon sonuçları Çizelge 4.10'da verilmiştir. ARX modellerine ait parametreler, belirgin dalga yüksekliği ve dalga periyodu için en küçük kareler yöntemiyle iteratif olarak belirlenmiş ve iterasyon sonundaki karesel ortalama hata değerleri sırasıyla 0,0018 ve 0,0024 olarak hesaplanmıştır. KG eğitme algoritması ile eğitilen ağların ve ARX modellerin, iki saatlik tahmin aralığı için test aşamasına ait sonuçları Çizelge 4.11'de; MGA eğitme algoritması ile eğitilen ağların test aşamasına ait sonuçlar ise Çizelge 4.12'de verilmiştir.

Çizelge 4. 10. Çok değişkenli yapay sinir ağlarının yapısı ve iterasyon sonuçları

Model	Ağın Yapısı	Eğitme Algoritması	KH	İterasyon
ETSA	$x_{12}h_{30}y_3$	KG	0,00110	94
ETSA	$x_{12}h_{30}y_3$	MGA	0,00180	10 000
İBSA	$x_{12}h_{35}y_3$	KG	0,00127	103
İBSA	$x_{12}h_{35}y_3$	MGA	0,00172	10 000

Çizelge 4.11-12’de verilen sonuçların determinasyon katsayıları dikkate alındığında, tek değişkenli modeller için Çizelge 4.5-6’da verilen sonuçlarla uyumlu olduğu söylenebilir. Eğitim algoritmaları ve ağ tipleri karşılaştırıldığında çok değişkenli modellerde de KG eğitim algoritması ile ETSA’nın daha başarılı olduğu görülmektedir (Çizelge 4.11). Ancak, çok değişkenli modellerde bütün test kümeleri için hesaplanan determinasyon katsayılarının genelde yüksek değerler almasına karşın (Çizelge 4.5), tek değişkenli modellere kıyasla katsayılar daha düşük bir düzeydedir. Bu durum, çok değişkenli modellerde yer alan rüzgar hızı değerlerinin, dalga parametrelerinin tahminine katkısının düşük olduğunu göstermekte olup eğitim veri kümesi hariç, bütün veri kümelerinde genel olarak dalga parametreleriyle rüzgar hızı arasındaki korelasyon ilişkisinin yüksek olmamasına bağlanabilir. Burada, bütün test veri kümeleri için genellenebilecek bir dalga-rüzgar ilişkisinin kurulamamasında, bölgedeki dalga hareketlerinin, çapraz korelasyon fonksiyonları dikkate alındığında, tümüyle yersel rüzgarların etkisinde olmaması yanında kısa dönemli dalga hareketlerinin incelenmesi etkili olmuştur. Çok değişkenli modellerin belirgin dalga yüksekliği ve dalga periyodu değerlerinin başarılı şekilde tahmin etmesine karşın, dalga yönü tahmininde başarısız olması tek değişkenli modellerde olduğu gibi yapay sinir ağlarının eğitilmesinin kısa dönemli veri tabanlarına dayandırılmasına bağlanabilir. Yine tek değişkenli ve çok değişkenli doğrusal modeller (AR) de, daha önce açıklanan nedenlerle, yapay sinir ağlarına göre dalga parametrelerinin tahmininde başarısız bulunmuştur.

Çizelge 4.11. KG eğitim algoritması ile eğitilen çok değişkenli yapay sinir ağlarına ve ARX modellere ait kısa tahmin aralıklı test sonuçları

Model	Parametre	Test 1		Test 2		Test 3		Test 4	
		MH	r	MH	r	MH	r	MH	r
ETSA	H _s	0,021	0,839	0,017	0,802	0,030	0,856	0,026	0,929
	T	0,030	0,833	0,036	0,872	0,035	0,825	0,038	0,910
	WD	0,016	0,038	0,020	0,311	0,015	0,231	0,021	0,561
İBSA	H _s	0,024	0,819	0,025	0,506	0,037	0,807	0,031	0,906
	T	0,034	0,789	0,041	0,825	0,040	0,789	0,037	0,907
	WD	0,024	-1,392	0,026	-0,493	0,029	-2,974	0,028	0,312
ARX (1,9)	H _s	0,023	0,168	0,013	-0,364	0,032	-0,198	0,023	0,240
ARX (1,9)	T	0,035	0,380	0,039	0,076	0,041	0,566	0,037	0,349

Çizelge 4.12. MGA eğitime algoritması ile eğitilen çok değişkenli yapay sinir ağlarına ait kısa tahmin aralıklı test sonuçları

Model	Parametre	Test 1		Test 2		Test 3		Test 4	
		MH	r	MH	r	MH	r	MH	r
ETSA	H _s	0,030	0,724	0,028	0,430	0,041	0,778	0,035	0,884
	T	0,036	0,781	0,040	0,844	0,041	0,792	0,043	0,887
	WD	0,030	-2,030	0,035	-1,040	0,032	-1,815	0,039	-0,248
İBSA	H _s	0,028	0,770	0,036	0,164	0,042	0,774	0,033	0,900
	T	0,040	0,718	0,0470	0,788	0,049	0,689	0,040	0,892
	WD	0,036	-4,829	0,043	-2,844	0,047	-9,420	0,038	-0,292

Test veri kümelerinin son 48 saatlik kısımları, tahmin edilen değerlerin geri besleme yoluyla girdi katmanına iletilmesiyle sentetik olarak üretilmiş; mutlak ortalama hata ve determinasyon katsayısı değerleri benzer şekilde, ağ tiplerine ve eğitime algoritmalarına bağlı olarak, Çizelge 4.13-4.14'de verilmiştir. Burada elde edilen sonuçlar, tek değişkenli modeller için yapılan uzun aralıklı tahminlerle uyumlu olup benzer şekilde, KG eğitime algoritması ile eğitilen ETSA daha yüksek determinasyon katsayıları vermiştir. Uzun aralıklı tahminler açısından tek ve çok değişkenli modeller arasındaki en önemli fark (4) nolu test kümesi için hesaplanan determinasyon katsayılarında gözlenmiştir: Tek değişkenli ETSA kullanılarak yapılan belirgin dalga yüksekliği ve dalga periyodu tahminlerinin determinasyon katsayıları sırasıyla 0,727 ve 0,631 (Çizelge 4.7) olmasına karşın; çok değişkenli ETSA ile yapılan tahminler için determinasyon katsayıları 0,880 ve 0,714 olarak (Çizelge 4.13) hesaplanmıştır. Kısa aralıklı tahminlerde çok ve tek değişkenli modellerin kullanılması çok büyük farklar göstermemekte, ancak uzun aralıklı tahminlerde rüzgar verileri ile desteklenen çok değişkenli modellerin daha başarılı tahminler yapabileceği görülmektedir.

Çizelge 4. 13. KG eğitme algoritması ile eğitilen çok değişkenli yapay sinir ağlarına ve ARX modellere ait uzun tahmin aralıklı test sonuçları

Model	Parametre	Test 1		Test 2		Test 3		Test 4	
		MH	r	MH	r	MH	r	MH	r
ETSA	H _s	0,025	0,793	0,020	0,700	0,048	0,697	0,035	0,880
	T	0,031	0,829	0,038	0,849	0,051	0,659	0,061	0,714
	WD	0,017	-0,080	0,022	0,151	0,018	-0,046	0,022	0,513
İBSA	H _s	0,035	0,450	0,037	-0,286	0,061	0,411	0,039	0,863
	T	0,040	0,709	0,0502	0,722	0,058	0,514	0,053	0,793
	WD	0,023	-1,362	0,028	-0,556	0,028	-2,281	0,032	0,136
ARX (1,9)	H _s	0,023	0,154	0,013	-0,382	0,000	-0,191	0,024	0,105
ARX (1,9)	T	0,038	0,295	0,037	0,064	0,042	0,565	0,03r	0,302

Çizelge 4. 14. MGA eğitme algoritması ile eğitilen çok değişkenli yapay sinir ağlarına ait uzun tahmin aralıklı test sonuçları

Model	Parametre	Test 1		Test 2		Test 3		Test 4	
		MH	r	MH	r	MH	r	MH	r
ETSA	H _s	0,030	0,304	0,028	0,203	0,041	0,222	0,035	0,791
	T	0,036	0,751	0,040	0,810	0,041	0,414	0,043	0,805
	WD	0,030	-2,132	0,035	-1,066	0,032	-2,735	0,039	-0,156
İBSA	H _s	0,039	0,389	0,057	-1,761	0,063	0,394	0,049	0,764
	T	0,043	0,687	0,060	0,629	0,073	0,129	0,046	0,835
	WD	0,045	-8,363	0,043	-2,863	0,074	-28,483	0,057	-1,712

Dalga parametrelerinin tek ve çok değişkenli modeller kullanılarak yapılan tahminlerinden elde edilen sonuçlar genel olarak aşağıda verilen başlıklar halinde özetlenebilir:


a. Test aşaması sonuçlarına göre, ortalama hata değerleri tüm modeller için sıfıra yakın değerler almasına karşın; daha önemli bir değerlendirme kriteri olan determinasyon katsayıları dikkate alındığında, yapay sinir ağlarının, doğrusal modellere (AR ve ARX) kıyasla çok üstün bir performans gösterdiği (rüzgar yönü tahmini dışında) görülmektedir.

b. AR ve ARX modeller tümüyle yapay sinir ağlarına bağlı olarak seçildiğinden bu modeller için kalıntılar, Andersen testi (Bayazıt, 1996) ile analiz edilmiş ve belirgin dalga yüksekliğine ait AR(1) modelinin ve dalga periyoduna ait ARX(1,9) modelinin uygun olmadığı belirlenmiştir. Ancak, bu modellerin yerine seçilen AR(3) ve daha düşük serbestlik derecesine sahip olan ARX modelleri de benzer sonuçlar


vermiştir. Bunun nedeni, lineer modellerin değişkenler arasındaki karmaşık ilişkiyi modellemekte yetersiz kalması ve yeni durumlar karşısında yapay sinir ağlarının gösterdiği esnekliği gösterememesidir. Doğrusal modellerden yalnızca model parametrelerinin elde edildiği eğitime veri kümeleri için 0,6 değerine kadar ulaşan determinasyon katsayılarına sahip tahminler elde edilebilmiştir. Genel olarak, Alanya deniz yöresi için yapılan bu çalışmada yapay sinir ağlarının yüksek determinasyon katsayılarına sahip dalga parametreleri tahmininde bulundukları ve eksik verilerin tamamlanmasında başarıyla uygulanan yöntemler oldukları görülmüştür.

c. Yapay sinir ağlarının performansı eğitime algoritmaları açısından determinasyon katsayıları dikkate alınarak değerlendirildiğinde KG eğitime algoritması ile eğitilen ağlar, tek ve çok değişkenli modeller için daha başarılı sonuçlar vermiştir. Bunun nedeni iterasyon sayısındaki azalmanın, ağı eğitime veri kümelerine bağımlılığını azaltması ve genelleme yeteneğini artırmasıdır. Böylece, yapay sinir ağı yeni veriler karşısında daha başarılı sonuçlar vermiştir. Eğitime algoritmasının seçimi, eğitime veri kümesinin toplam gözlem verilerinin küçük bir bölümünden oluşması ve zaman serisinin karmaşık yapısı nedeniyle bu çalışmada önem kazanmıştır.


d. ETSA genel olarak, hem tek değişkenli hem de çok değişkenli zaman serileri için İBSA'dan daha yüksek bir performans göstermiştir. Tek değişkenli modeller için determinasyon katsayıları dikkate alındığında, eğitime algoritmalarının KG olması halinde, her iki ağ arasındaki fark esas olarak uzun aralıklı tahminlerde (48 saatlik) gözlenmiştir. Örneğin, (4) nolu test kümesi için tahminde (2 saatlik kısa aralıklı) önemli bir fark gözlenmezken; uzun aralıklı tahminde ETSA, H_s ve T değerleri için sırasıyla % 252 ve % 122 oranlarında daha yüksek bir performans göstermiştir (Şekil 4.9–4.10). Benzer durum çok değişkenli modeller kıyaslandığında H_s değerleri için (2) nolu test kümesinde % 140; T değerleri için (3) nolu test kümesinde % 22 oranlarında daha yüksek bir performans şeklinde gözlenmiştir (Şekil 4.11-4.12). Ayrıca, İBSA'na bağlı uzun aralıklı tahminler genel olarak determinasyon katsayılarının belirgin oranlarda düşmesine neden olmuştur.




Şekil 4.9. Tek değişkenli yapay sinir ağlarına bağlı olarak tahmin edilen belirgin dalga yüksekliği değerleri için determinasyon katsayılarının değişimi



Şekil 4.10. Tek değişkenli yapay sinir ağlarına bağlı olarak tahmin edilen dalga periyodu değerleri için determinasyon katsayılarının değişimi




Şekil 4.11. Çok değişkenli yapay sinir ağlarına bağlı olarak tahmin edilen belirgin dalga yüksekliği değerleri için determinasyon katsayılarının değişimi




Şekil 4.12. Çok değişkenli yapay sinir ağlarına bağlı olarak tahmin edilen dalga periyodu değerleri için determinasyon katsayılarının değişimi

e. Uzun aralıklı tahmin yapabilme açısından tek değişkenli ETSA, çok değişkenli ETSA yönteminden tahmin açısından belirgin bir fark göstermemiş; (1-3) nolu test kümelerinde daha iyi performans sergilemiştir. Ancak, tek değişkenli ETSA ile 48 saatlik süre sonunda tahmin edilen değerler, hata oranlarının kümülatif olarak zamanla artması sonucunda, 7130. saatten sonra zaman serisinin iyi modellenemediği görülmüştür ve limit hata değerlerine ulaşılmıştır (Şekil 4.13-4.14). Şekil 4.13-14’de görüldüğü gibi belirgin dalga yükseklikliğinin ve dalga periyodunun sentetik olarak üretilen ilk değerleri, bir önceki tahmin edilen değerlerle uyumlu olarak bir artış eğilimine uymakta ve hata oranlarının artmasıyla sabit bir değere ulaşmaktadır. Bu durum tahmin edilen ilk değerlerin başka bir deyişle ağların eğitilmesinde gözönüne alınan tahmin aralığının (2 saat) ağın tahmin yeteneğini önemli ölçüde etkilediğini göstermektedir. Ancak, 48 saatlik sürenin uzun bir süre olduğu ve bu uzun aralıklı tahminlerde yapay sinir ağlarının, örneğin 6, 12, 24 saatlik gibi farklı tahmin aralıkları için, ayrı ayrı eğitilerek kullanılmasının uygun olacağı söylenebilir.


f. Uzun aralıklı tahminlerde, çok değişkenli ETSA’nın kullanılmasıyla girdilerin rüzgar verilerini de içermesi nedeniyle limit hata değerlerine ulaşılmamış, fakat rüzgar verilerinin meteoroloji istasyonundan sağlanması nedeniyle daha iyi sonuçlara da ulaşılamamıştır. Şekil 4.15-4.18’de çok değişkenli ETSA için (1) ve (4) nolu test kümelerine ait H_s ve T değerlerinin kısa ve uzun aralıklı tahminleri verilmiştir. Şekil 4.15-16’da görüldüğü (1) nolu test kümesi için sentetik olarak üretilen belirgin dalga yükseklikleri ve dalga periyodu değerleri tek değişkenli modellerde olduğu gibi tahmin edilen ilk değerlere bağlı olarak bir artış eğilimi izlememekte ve ölçülen değerlerle daha uyumlu bir eğilim sergilemektedir. Aynı davranış eğilimi (4) nolu test kümesi için sentetik olarak üretilen dalga parametrelerinde de sözkonusudur (Şekil 4.17-18). Bu durum, gözönüne alınan bölgedeki rüzgar-dalga ilişkisini daha güçlü verecek veri tabanlarının olması halinde rüzgar verileriyle desteklenen uzun aralıklı tahminlerin daha başarılı olacağını göstermektedir.




Şekil 4.13. 1 nolu test kümesi için tek değişkenli yapay sinir ağları ile yapılan kısa ve uzun aralıklı belirgin dalga yüksekliği tahminlerinin ölçülen değerlerle karşılaştırılması




Şekil 4.14. 1 nolu test kümesi için tek değişkenli yapay sinir ağları ile yapılan kısa ve uzun aralıklı dalga periyodu tahminlerinin ölçülen değerlerle karşılaştırılması




Şekil 4.15. 1 nolu test kümesi için çok değişkenli Elman tipi sinir ağı ile yapılan kısa ve uzun aralıklı belirgin dalga yüksekliği tahminlerinin ölçülen değerlerle karşılaştırılması



Şekil 4.16. 1 nolu test kümesi için çok değişkenli Elman tipi sinir ağı ile yapılan kısa ve uzun aralıklı dalga periyodu tahminlerinin ölçülen değerlerle karşılaştırılması



Şekil 4.17. 4 nolu test kümesi için çok değişkenli Elman tipi sinir ağı ile yapılan kısa ve uzun aralıklı belirgin dalga yüksekliği tahminlerinin ölçülen değerlerle karşılaştırılması



Şekil 4.18. 4 nolu test kümesi için çok değişkenli Elman tipi sinir ağı ile yapılan kısa ve uzun aralıklı dalga periyodu tahminlerinin ölçülen değerlerle karşılaştırılması

Sonuç olarak, Elman tipi yapay sinir ağlarının (ETSA) eksik dalga verilerinin tamamlanmasında daha iyi sonuçlar verdiği; kısa aralıklı tahminlerde, ağın tek veya çok değişkenli olmasının önemli bir fark göstermediği, uzun aralıklı tahminlerde rüzgar verilerinin, güvenilir olması koşuluyla, dalga verilerinin tahminine önemli katkıda bulunacağı görülmüştür. Eğitim aşamasında kullanılan dalga ölçümü verilerinin yeterli uzunlukta olmaması ağların tahmin performansını önemli ölçüde etkilemektedir. Bu aşamada kullanılacak veri sayısındaki artış, yapay sinir ağlarının tahmin yeteneğini oldukça artıracaktır.

Doğrusal modellerin yeterli olduğu tahmin problemlerinde yapay sinir ağlarının kullanılması zaman ve maliyet açısından uygun değildir. Ancak yapay sinir ağları, karmaşık bir ilişki gösteren süreçlerin modellenmesinde, doğrusal olmayan mevcut yöntemlere kıyasla daha kolay uygulama olanağı sağlamaktadır.

Bu çalışmada, Alanya istasyonunda işletme sırasında ortaya çıkan sorunlar nedeniyle meydana gelen eksik dalga parametreleri yapay sinir ağları ile tahmin edilmiş ve böylece dalga parametrelerinin tahmininde alternatif bir yöntem denenmiştir. Yapay sinir ağları, doğrusal modellere kıyasla yüksek bir performans göstermiştir. ETSA, özellikle uzun aralıklı verilerin tamamlanmasında başarıyla uygulanmıştır. Yapay sinir ağları, veri tabanlı modellemeye dayandığından kıyı yapılarının tasarım aşaması yanında, deniz mühendisliği uygulamalarında ve veri işletimi aşamasında bilgisayar süresi açısından kolay uygulanabilir, ekonomik ve etkin (robust) yöntemlerdir. Dalga parametrelerinin ve rüzgar-dalga ilişkisinin karmaşık yapısı dikkate alındığında, rüzgar verilerinin güvenilir olması ve eğitim aşamasında kullanılan verilerin uzun dönemli elde edilebilmesi durumunda bu tekniklerin, yalnızca rüzgar verilerine bağlı olarak da uygun sonuçlar vereceği beklenebilir.


noktası”nın çok boyutlu koordinat sisteminin merkeze olan uzaklığına bağlı olarak belirlenmektedir.

Taş dolgu dalgakıranların içerdiği yüksek derecedeki belirsizlikler dikkate alındığında, belirsizlikler üzerine kurulan yapay zeka teknikleri, istatistiksel yöntemlerle birlikte, bu yapıların tasarımında kullanılabilecek alternatif yaklaşımlardan birini oluşturmaktadır. Bu bölümde, yapay zeka teknikleri, taş dolgu dalgakıranların tasarımına iki farklı aşamada uygulanmıştır. Birinci aşamada deterministik tasarıma alternatif olarak yapay sinir ağları, bulanık sistemler ve bulanık sinir ağları kullanılmış; ikinci aşamada ise taş dolgu dalgakıranlarda güvenilirlik indeksi, ikinci moment yaklaşımı ve genetik algoritmalar optimizasyonu ile belirlenmiştir. Elde edilen sonuçlara bağlı olarak yapay zeka tekniklerinin performansı, mevcut yaklaşımlarla karşılaştırılarak değerlendirilmiştir. Burada amaç, yüksek maliyet gerektiren taş dolgu dalgakıranların daha ekonomik ve daha emniyetli olarak tasarımında, yapay zeka tekniklerinin kullanılma olanaklarının araştırılması olmuştur.

Mersin Yat Limanı ana dalgakıranının tasarımı için, Mersin deniz yöresinde, en yüksek belirgin dalga yükseklikleri olasılık dağılımı elde edilmiştir (Şekil 5.2). Bu amaçla, 25 yıllık rüzgar verileri ve Bölüm 4’de eksik ölçümleri yapay sinir ağları ile tamamlanan dalga verileri kullanılarak, maksimum yıllık belirgin dalga yüksekliklerinin Şekil 5.2’de denklemi verilen Fisher Tippet Tip I (Gumbel) olasılık dağılımı ile modellenebileceği saptanmıştır. Böylece uzun dönem en yüksek dalga istatistiği yapay sinir ağları ile tamamlanan dalga ölçümleri ile desteklenmiştir.

5.1. Taş Dolgu Dalgakıranlarda Deterministik Tasarım

Yüksek maliyete sahip taş dolgu dalgakıranlarda en önemli hasar şeklini koruma tabakasında ortaya çıkacak hasarlar oluşturmaktadır. Koruma tabakasının tasarımında, genellikle yük ve dayanım değişkenleri arasındaki statik denge durumunu ifade eden Hudson ve Van der Meer denklemleri kullanılmaktadır (Hudson, 1953; Van der Meer, 1988).



Şekil 5.2. Mersin deniz yöresinde, en yüksek belirgin dalga yükseklikleri Fisher Tippet Tip I (Gumbel) olasılık dağılımı

Ancak, taş dolgu dalgakıranların tasarımında yaygın olarak kullanılan Van der Meer denklemleri hidrolik model deneylerinin sonuçlarından elde edilmiş ve deney verilerini ortalama olarak ifade edebilen eşitliklerdir ve bu nedenle tasarım aşamasında karşılaşılan önemli belirsizlik kaynaklarıdır.

Van der Meer denklemleri, Hudson denkleminin, (Hudson, 1953) düzenli dalga koşullarını yansıtmaması yanında dalga dönemi, geçirgenlik gibi parametreleri ihmal etmesi nedeniyle daha gelişmiş bir özellik göstermektedir ve model deneylerinden elde edilen sonuçlara bağlı olarak Van der Meer tarafından sıçrayarak ve yansıyarak kırılan dalga durumları için sırasıyla aşağıdaki şekillerde verilmiştir (Van der Meer, 1988):

$$N_s = [6.2P^{0.18} (\frac{S}{\sqrt{N}})^{0.2}] / \sqrt{\varepsilon_m} \quad \varepsilon_m < \varepsilon_c \quad (5.1)$$

$$N_s = 1.0P^{-0.13} (\frac{S}{\sqrt{N}})^{0.2} \sqrt{\cot \theta} \varepsilon_m^P \quad \varepsilon_m \geq \varepsilon_c \quad (5.2)$$

$$\varepsilon_m = \frac{\tan \theta}{\sqrt{2\pi H_s / g T_m^2}} \quad (5.3)$$

$$(5.4)$$

$$\varepsilon_c = (6.2P^{0.31} \sqrt{\tan \theta})^{1/(P+0.5)}$$

Burada, $N_s = \frac{H_s}{\Delta D_{n50}}$ ve $S = \frac{A}{D_{n50}^2}$ olup N_s : stabilite sayısı, P : dalgakıranın permeabilite katsayısı, S : hasar seviyesi, N : fırtınadaki dalga sayısı, ε_m : boyutsuz Iribarren parametresi, ε_c : boyutsuz Iribarren parametresinin kritik değeri, θ : koruma tabakasının eğim açısı, H_s : dalgakıran topuğundaki belirgin dalga yüksekliği, Δ : koruma tabakası taşının göreceli yoğunluğu, D_{n50} : koruma tabakası taşının çapı, A : dalgakıran kesitindeki hasar alanı, g : yerçekimi ivmesi, T_m : ortalama dalga dönemi (periyodu) olarak alınmıştır. Türkiye'de dalgakıran projelerinin ön projelendirme aşamalarında yaygın olarak kabul edilen hasar seviyesi Hudson denkleminin kullanılması halinde % 0-5 (hasar meydana gelmemesi durumu) arasında değişir ve koruma tabakası, köşeli ve pürüzlü ocak taşlarının rassal olarak iki tabaka halinde yerleştirilmesi ile elde edilir. Bu hasar aralığı Van der Meer denklemleri için hasar seviyesinin $S=2$ olması haline karşılık gelmektedir. Hudson denklemi için % 5-10, 10-15, 15-20, 20-30, 30-40 ve 40-50 aralıklarında verilen hasar seviyeleri ise Van der Meer denklemleri için sırasıyla 6, 10, 14, 20, 28 ve 36 olarak verilen hasar seviyelerine karşılık gelmektedir (Van der Meer, 1988).

5.2. Taş Dolgu Dalgakıranlarda Yapay Sinir Ağları, Bulanık Sistemler ve Bulanık Sinir Ağları ile Tasarım

İleri beslemeli denetimli sinir ağları karmaşık sistemleri, ayrıntılı matematiksel modellere ihtiyaç duyulmaksızın modelleyebilmekte; bulanık sistemler uzman bilgisini temsil eden bulanık kurallar ve sözel değişkenler yardımıyla belirsizlikleri işleyebilmektedir. İleri beslemeli denetimli sinir ağlarının, girdi ve çıktı vektörlerinin kesin değerler içermesi dolayısıyla arakeştirime yönelik olarak çalışması; bulanık sistemlerin ise sözel değişkenler yardımıyla belirsizlikleri işleyebilmesine karşın öğrenebilen bir sistem olmaması ve bulanık alt kümelerin çoğunlukla deneme-yanılma yoluyla belirlenmesi, bu tekniklerin dezavantajlarıdır. Yapay sinir ağları ve bulanık sistemler, eğitime için gerekli verilerin olması halinde, bulanık sinir ağları şeklinde kombine edilerek belirtilen dezavantajlar giderilebilmektedir.

Taş dolgu dalgakıranların tasarımında, Van der Meer denklemlerine alternatif olarak, ileri beslemeli denetimli sinir ağları, bulanık sistemler ve bulanık sinir ağlarından oluşan yapay zeka teknikleri uygulanarak değişik yapay zeka tekniklerinin performansları değerlendirilmiş, ayrıca deterministik tasarım sonuçları yapay zeka tekniklerinin sonuçları ile karşılaştırılmıştır.

Bu çalışmanın ilk kısmında, taş dolgu dalgakıranlar için stabilite sayısı, sıçrayarak ve yansıyarak kırılan dalga durumları için yapay sinir ağları yardımıyla tahmin edilmiş ve ağın yapısı P , S , N , $\cot \theta$ ve ϵ_m değerleri girdi, N_s değerleri ise çıktı olacak şekilde düzenlenmiştir. Değişkenlerin değer aralıkları, Van der Meer (1988) tarafından yapılan hidrolik model deneylerine ait veri tabanına bağlı olarak saptanmış ve Çizelge 5.1’de verilmiştir.

Çizelge 5.1. Van der Meer denklemlerindeki değişkenlerin değer aralıkları

Değişken	Maksimum	Minimum
Permeabilite katsayısı (P)	0,60	0,10
Eğim (Cot θ)	6,00	1,50
Stabilite sayısı (N_s)	4,30	0,80
Iribarren sayısı (ϵ_m)	7,60	0,70
Hasar seviyesi (S)	46,40	0,30
Dalga sayısı (N)	3000	1000


Ağın eğitilme ve test edilme aşamasında Van der Meer (Van der Meer, 1988) tarafından yapılan hidrolik model deneylerine ait toplam 554 veri kümesinin yaklaşık % 20'si, değişkenlerin aldığı maksimum ve minimum değerleri kapsayacak şekilde (Çizelge 5.1), eğitime geri kalan kısmı ise test aşamasında kullanılmıştır. Her iki aşama için de veriler rassal olarak ve dalga spektrumunun PM (Pierson Moskowitz) olduğu durumlar dikkate alınarak seçilmişlerdir. Eğitime aşamasında, momentum katsayılı gradyen azalma eğitime algoritması kullanılmış; ara katmanlardaki hücre sayısı dört ve eğitime parametreleri olan öğrenme oranı ve momentum katsayısı sırasıyla 0,3 ve 0,6 olarak belirlenmiştir.

Aktivasyon fonksiyonları, ara katmanlarda sigmoidal; çıktı katmanlarında lineer olup hata fonksiyonu karesel hataların ortalaması olarak alınmıştır. Uygun ağ yapısı (x_k, h_s, y_z) ve hata değerinin iterasyon sayısına bağlı değişimi, k: girdi katmanındaki hücre sayısı, s: ara katmandaki hücre sayısı ve z: çıktı katmanındaki hücre sayısı olmak üzere Çizelge 5.2'de özetlenmiştir. Test sonuçları korelasyon katsayıları (R) ile birlikte dağılım diyagramı halinde Şekil 5.3'de verilmiştir.


Çizelge 5.2. İleri beslemeli denetimli sinir ağı için eğitime aşamasına ait sonuçlar

Ağın Yapısı	İterasyon Sayısı	Hata
$x_5h_4y_1$	100	0,0171
$x_5h_4y_1$	300	0,0104
$x_5h_4y_1$	500	0,0091
$x_5h_4y_1$	1000	0,0086


Stabilite sayıları, toplam veri kümesi için Van der Meer denklemleri kullanılarak da hesaplanmış ve sonuçlar dağılım diyagramı şeklinde, dalga sayılarına bağlı olarak, Şekil 5.4-5.5'te verilmiştir.



Şekil 5. 3. İleri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı



Şekil 5. 4. Van der Meer denklemleri ile tahmin edilen stabilite sayılarına ait dağılım diyagramı ($N=1000$)




Şekil 5. 5. Van der Meer denklemleri ile tahmin edilen stabilite sayılarına ait dağılım diyagramı ($N=3000$)

Test aşamasında, ileri beslemeli denetimli sinir ağı ($x_5h_4y_1$) kullanılarak tahmin edilen değerlerle deney sonuçları arasındaki korelasyon ($R=0,804$) Van der Meer denklemleri ile tahmin edilen stabilite sayılarının korelasyonu ($R=0,891$) mertebesindedir. Ancak, ağ yapısı kadar kullanılan veri tabanları da yapay sinir ağlarının performansını etkileyen faktörlerdir ve girdilerin istatistiksel anlamda birbirinden bağımsız (decorrelate) olarak örneğin Esas Bileşen Analizi (Principal Component Analysis) ile yeni bir koordinat düzleminde tanımlanması (Olofsson et al., 1998; Choi and Park, 2001) yapay sinir ağlarının modelleme yeteneğini artırabilmektedir. Bu nedenle mevcut veri tabanı, PCA (Principal Component Analysis) yardımıyla yeniden düzenlenmiş ve eğitme işlemi tekrarlanmıştır.

Esas Bileşen Analizi (EBA) çok değişkenli veri kümelerinin analizinde kullanılan istatistiksel bir doğrusal veri dönüştürme yöntemidir (Dunteman, 1976). Bu yöntemle gözönüne alınan veri kümesi, gerçek değişkenlere bağlı olarak tanımlanan esas bileşenlerle (principal components) tanımlanır ve esas bileşenler birbirine dik düzlemler olmak üzere gerçek değişkenlerin doğrusal kombinasyonlarına karşılık gelir (EK 1). Mevcut değişkenlerin yeni değişkenlere dönüştürülmesi (esas bileşenler) işlemi kısaca varyans en büyükleme olup esas bileşenler, girdi vektörlerine (gerçek değişkenlere) ait kovaryans matrisinin birbirine dik (orthogonal) özvektörlerinden oluşmaktadır. Esas bileşenler önem derecelerine göre adlandırılırlar ve birinci mertebeden esas bileşenin gerçek değişkenlerin sahip olduğu ilişkiyi en büyük varyans değerine bağlı olarak açıkladığı söylenebilir; daha yüksek mertebeden esas bileşenler ise azalan varyans değerlerine göre sıralanırlar.

İnsan beyninin uyarımları (girdileri) birbirinden bağımsız olarak ve en önemli uyarımlar üzerinde odaklanarak algılamak zorunda olması (Schittenkopf et. al., 1997) esas bileşen analizi ile yapay sinir ağlarının birlikte kullanılmasının temelini oluşturmaktadır. Esas bileşen analizi ile girdi vektörlerinin boyutunun azaltılması ve değişkenlerin birbirinden bağımsız olarak tanımlanması yapay sinir ağlarının genelleme yeteneğini artırabilmektedir. Yapay sinir ağlarının performanslarını artırmak için kullanılan başka bir yaklaşım da eğitme aşamasında kullanılan veri tabanına rassal değişken (noise) ilave edilmesidir (Patterson, 1996).


İleri beslemeli denetimli sinir ağının eğitime ve test aşamasında kullanılan girdi vektörlerinin oluşturduğu veri tabanı için (P, S, N, $\cot \theta$ ve ϵ_m) yapılan Esas Bileşen Analizi sonucunda veri tabanının birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımının geniş bir aralıkta değiştiği (Şekil 5.6); ağırlık faktörleri dikkate alındığında birinci mertebeden esas bileşen üzerinde dalga sayısının çok düşük bir etkisi olduğu (Çizelge 5.3); ilk dört esas bileşenin ise toplam değişimin (varyansın) % 100'e yakın kısmını açıkladığı (Şekil 5.7) saptanmıştır.



Şekil 5.6. Girdi vektörlerinin oluşturduğu veri tabanına ait verilerin birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımı

Çizelge 5.3. Esas bileşenler için gerçek değişkenlere bağlı ağırlık faktörleri

Esas Bileşen	Ağırlık faktörü				
	P	Cot θ	ϵ_m	S	N
1	-0,511	0,629	-0,545	0,206	0,049
2	0,225	-0,138	-0,054	0,675	0,686
3	-0,474	0,073	0,422	-0,435	0,633
4	0,514	0,024	-0,541	-0,554	0,353



Şekil 5.7. Esas bileşenlere ait varyans değerleri

Esas bileşenler, gerçek değişkenlere bağlı olarak üretilen birbirinden bağımsız sentetik değişkenlerdir ve ağırlık faktörleri, esas bileşenlerle gerçek değişkenler arasındaki korelasyonu ifade etmekte, ayrıca değişkenlerin kendi aralarındaki ilişkiyi de göstermektedir. Birinci mertebeden esas bileşen, en büyük varyans değerine sahip olduğu için, gerçek veriler arasındaki ilişkiyi en yüksek derecede açıkladığı kabul edilen bileşendir. Örneğin, Çizelge 5.3’de görüldüğü gibi birinci mertebeden esas bileşen üzerinde dalga sayısının etkisi ihmal edilebilecek seviyelerdedir ve artı

değerli ağırlık faktörlerine sahip değişkenlerle ($\text{Cot } \theta$, S) ağırlık faktörlerinin eksi değerler aldığı değişkenler arasında (P , ϵ_m) ters yönlü bir ilişkinin varlığı gözlenmektedir. Bu nedenle birinci mertebeden esas bileşen genel olarak, artı ve eksi değerli ağırlık faktörlerine sahip değişkenler grubu arasındaki göreceli oransal ilişkiyi yansıtmaktadır. İkinci mertebeden esas bileşenin, eksi değerler alan ağırlık faktörlerinin etkisi düşük olduğu için ihmal edilmesi halinde, permeabilite katsayısında, hasar seviyesinde ve dalga sayısındaki toplam değişkenliği ifade ettiği görülmektedir. Üçüncü mertebeden esas bileşen, koruma tabakası eğiminin ($\text{Cot } \theta$) ağırlık faktörü küçük olduğundan ihmal edilmesi durumunda, Iribarren ve dalga sayısını, hasar seviyesine ve permeabilite katsayısına oranla daha fazla yansıtmaktadır. Esas bileşenler varyans en büyüklemesini ifade ettiğinden, ilk üç mertebedeki esas bileşenlerin eklenik olarak toplam varyansı, Şekil 5.7’de yaklaşık olarak değişkenliğin % 90’lık kısmını açıklamaktadır.

İleri beslemeli denetimli yapay sinir ağlarının performansını etkileyen faktörlerden biri de veri tabanlarının aynı girdilere karşılık farklı çıktılara sahip olmasıdır (Skapura, 1996). Bu nedenle, çalışmada kullanılan hidrolik model deneylerine ait toplam veri kümesi, aynı girdiler aynı çıktıları verecek şekilde yeniden düzenlenmiştir. Veri kümesinde aynı girdilere ait farklı çıktıların gözlenmesinin nedeni özellikle farklı dalga sayısının 1000 ve 3000 olması durumlarında girdi değerlerinin (P , S , N , $\text{cot } \theta$ ve ϵ_m) değişmesine karşılık çıktı değerlerinin (N_s) aynı kalması olmuştur. Bu durumda olan veri gruplarından (girdi vektörleri) yalnızca biri rassal olarak seçilmiş ve ağırlık eğitme ve test aşamasında kullanılan veri tabanı aynı girdiler aynı çıktıları sahip olacak şekilde yeniden belirlenmiştir. Düzenlenmiş veri kümesi toplam 166 veri kümesinden oluşmuş ve toplam veri kümesine ait istatistik bilgiler Çizelge 5.4’de; düzenlenmiş veri kümesinin istatistik özellikleri ise Çizelge 5.5’de özetlenmiştir.

Çizelge 5.4. Toplam veri kümesine ait istatistiki özellikler

Değişken	P	Cot θ	N_s	ε_m	S	N
Maksimum	0,1	6,0	4,3	7,6	46,4	3000
Minimum	0,6	1,5	0,8	0,7	0,3	1000
Ortalama	0,3	2,9	2,2	3,0	7,1	2000
Standart Sapma	0,2	1,3	0,6	1,4	6,4	1009


Çizelge 5.5. Düzenlenmiş veri kümesine ait istatistiki özellikler

Değişken	P	Cot θ	N_s	ε_m	S	N
Maksimum	0,1	6,0	4,3	7,6	30,8	3000
Minimum	0,6	1,5	0,8	0,7	0,3	1000
Ortalama	0,3	3,0	2,3	2,9	7,6	1998
Standart Sapma	0,2	1,3	0,7	1,5	6,3	1030


Düzenlenmiş veri kümesi için de yapılan Esas Bileşen Analizi, veri tabanının birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımının geniş bir aralıkta değiştiği (Şekil 5.8) ve birinci mertebeden esas bileşen üzerinde dalga sayısının çok düşük bir etkisi olduğunu (Çizelge 5.6) göstermiştir. Bu veri grubu için ilk dört esas bileşene ait varyans değerleri Şekil 5.9' da verilmiştir.

Çizelge 5.6. Düzenlenmiş veri kümesine ait esas bileşenler için gerçek değişkenlere bağlı ağırlık faktörleri

Esas Bileşen	Ağırlık faktörü				
	P	Cot θ	ε_m	S	N
1	-0,487	0,639	-0,558	0,203	-0,033
2	0,247	-0,109	-0,127	0,692	0,656
3	-0,550	0,048	0,367	-0,353	0,659
4	0,475	0,111	-0,525	-0,594	0,363



Şekil 5.8. Düzenlenmiş veri kümesi için girdi vektörlerinin oluşturduğu veri tabanına ait verilerin birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımı




Şekil 5.9. Düzenlenmiş veri kümesi için esas bileşenlere ait varyans değerleri


Düzenlenmiş veri kümesi ile eğitime aşamasında kullanılan veri özelliklerine bağlı olarak dört farklı ileri beslemeli ağ oluşturulmuştur. Oluşturulan bu ağların ara katmanlarında bipolar sigmoidal; çıktı katmanlarında lineer aktivasyon fonksiyonları kullanılmıştır. Hata fonksiyonu karesel hataların ortalaması olarak alınmıştır. Eğitim aşamasında momentum katsayılı gradyan azalma algoritması kullanılmış ve öğrenme oranları sabit alınmamış ve her iterasyonda (adaptive learning rate) hata fonksiyonun değerine bağlı olarak değiştirilmiştir. Öğrenme oranları için başlangıç değeri 0,001 olarak alınmıştır. İlk aşamada, düzenlenmiş veri kümesinin yaklaşık % 54 oranındaki gerçek kısma ortalaması sıfır ve standart sapması 0,13 olan normal dağılımlı rassal değişken (noise) ilave edilmiş ve bu veri grubu, gerçek veri grubuna ilave edilerek eğitim aşamasında kullanılan girdi vektörü sayısı iki katına (188) çıkarılmıştır. Gerçek veri kümesinin yaklaşık % 46 oranındaki kısmı ise ağı test edilme aşamasında kullanılmıştır. Bu aşamaya ait uygun ağ yapısı ($x_k h_s y_z$), momentum katsayısı, iterasyon sayısı ve karesel hataların ortalaması (KH) ve test aşamasına ait korelasyon katsayısı Çizelge 5.7’de birinci satırda verilmiştir. Test sonucuna ait dağılım diyagramı ise Şekil 5.10’da verilmiştir. Stabilitate sayıları, test veri kümesi için Van der Meer denklemleri kullanılarak da hesaplanmış ve dağılım diyagramı korelasyon katsayısı (0,930) ile birlikte Şekil 5.11’de verilmiştir.

Çizelge 5.7. Düzenlenmiş veri kümeleri ve esas bileşenler kullanılarak oluşturulan ileri beslemeli denetimli yapay sinir ağlarının eğitime aşamasına ait sonuçlar

Girdi vektörü	Veri sayısı	Ağ yapısı	Momentum katsayısı	İterasyon sayısı	KH	R
Gerçek veri + rassal değişken (P, S, N, $\cot \theta$ ve ϵ_m)	188	$x_3 h_4 y_1$	0,6	3000	0,0207	0,936
Gerçek veri + rassal değişken (P, S, $\cot \theta$ ve ϵ_m)	188	$x_3 h_4 y_1$	0,5	3000	0,033	0,927
EBA+ YSA (İlk beş esas bileşen)	100	$x_3 h_5 y_1$	0,7	1000	0,0217	0,928
EBA+YSA (İlk dört esas bileşen)	100	$x_4 h_5 y_1$	0,6	1000	0,0284	0,906




Şekil 5. 10. Düzenlenmiş veri tabanı ile eğitilen (gerçek veri + rassal değişken) ve girdileri P , S , $\cot \theta$, N ve ε_m değerlerinden oluşan ileri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı




Şekil 5.11. Van der Meer denklemleri ile tahmin edilen stabilite sayılarına ait dağılım diyagramı


İkinci aşamada eğitme aşamasında kullanılan veri tabanı aynı şekilde oluşturulmuş ancak ağına girdileri P , S , $\cot \theta$ ve ϵ_m değerlerinden meydana getirilmiş ve dalga sayısı (N) değerleri kullanılmamıştır. Bu aşamaya ait uygun ağı yapısı ve diğer parametreler Çizelge 5.7’de ikinci satırda; test sonucunu gösteren dağılım diyagramı Şekil 5.12’de verilmiştir. Üçüncü aşamada, ağların eğitilmesinde gerçek değerlerin yerine ilk beş esas bileşen; dördüncü aşamada ise ilk dört esas bileşen kullanılmış ve bu aşamalar sırasıyla Çizelge 5.7’nin üçüncü ve dördüncü satırlarında özetlenmiş; test sonuçları dağılım diyagramları ile Şekil 5.13-14’te verilmiştir. Üçüncü ve dördüncü aşamalarda, düzenlenmiş veri tabanının yaklaşık % 60 oranındaki kısmı ağların eğitilmesinde geri kalan kısmı test edilmesinde kullanılmıştır. Bütün aşamalarda oluşturulan yapay sinir ağları korelasyon katsayıları dikkate alındığında yüksek performans göstermekle birlikte özellikle birinci aşamaya ait yapay sinir ağı literatürde yer alan (Mase et. al., 1995) çalışmadan farklı olarak Van der Meer denklemleriyle aynı oranda yüksek performans göstermiştir.



Şekil 5. 12. Düzenlenmiş veri tabanı ile eğitilen (gerçek veri + rassal değişken) ve girdileri P , S , $\cot \theta$ ve ϵ_m değerlerinden oluşan ileri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı



Şekil 5.13. Düzenlenmiş veri tabanı ile eğitilen ve girdileri ilk beş esas bileşenden oluşan ileri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı




Şekil 5.14. Düzenlenmiş veri tabanı ile eğitilen ve girdileri ilk dört esas bileşenden oluşan ileri beslemeli denetimli sinir ağı için test aşamasına ait dağılım diyagramı

Çizelge 5.7’de verilen sonuçlar genel olarak değerlendirildiğinde en yüksek korelasyonlu tahminler yapay sinir ağının girdi değerlerine rassal değişken ilave edilmesi halinde gözlenmiştir. Girdi vektörlerine rassal değişken ilave edilmesinin, yapay sinir ağlarının eğitilme aşamasında ağırlık faktörlerine bağlı olarak tanımlanan hata fonksiyonunun optimizasyonu (minimizasyonu) sırasında yersel minimum noktalardan kaçınmayı sağladığı bilinmektedir. Ancak, gradyen azalma eğitme algoritmasının değişen öğrenme oranlarıyla yapılması ve mevcut eğitme veri kümesinin rassal değişken ilave edilerek artırılması da ağın performansını artıran faktörler olmuştur. Bu aşamaya ait tahminler (Şekil 5.10) aynı koşullarda Van der Meer denklemlerine (Şekil 5.11) göre yüksek korelasyon katsayısı vermiştir. Yapay sinir ağının girdi değerlerinin dalga sayısını içermemesi durumunda da yüksek kabul edilebilecek korelasyon katsayısına ulaşılması, dalga sayısının düşük etkisini ortaya koyan Esas Bileşen Analizinin sonuçları ile uyumludur (Şekil 5.12). Ayrıca, ilk dört ve beş esas bileşenin girdi olarak kullanılması yine yüksek korelasyonlu sonuçlar vermiştir (Şekil 5.13-14). Burada, birbirinden bağımsız girdi vektörlerinin (esas bileşenlerin) yapay sinir ağına verilmesi başka bir deyişle değişkenlerin önem derecelerine göre (en büyük varyans değerleriyle) tanımlanması verilerin işlenmesini kolaylaştırmış ve yapay sinir ağının genelleme yeteneğini artırmıştır.

Çalışmanın ikinci kısmında, taş dolgu dalgakıranların tasarımına yönelik olarak oluşturulan bulanık sistemin girdileri belirgin dalga yüksekliği (H_s), ortalama dalga periyodu (T) ve hasar seviyesi (S) olarak alınmış; stabilite sayısı ise sistemin çıktısını (N_s) meydana getirmiştir. Sistemin bulanık kural tabanını meydana getiren kurallar, girdi ve çıktılarının değişik kombinasyonları gözönüne alınarak kurulmuştur. Kural tabanı oluşturulurken Van der Meer denklemlerinden yararlanılmış ve oluşturulan bulanık sistem şematik olarak Şekil 5.15’te verilmiştir.

Sistemin girdilerini oluşturan değişkenlerden belirgin dalga yüksekliği ve ortalama dalga periyodu, düşük (D), orta (O), yüksek (Y) ve çok yüksek (ÇY) olmak üzere dört farklı bulanık alt kümeyle; hasar seviyesi ise düşük (D), orta (O) ve yüksek (Y) olmak üzere üç farklı bulanık alt kümeyle karakterize edilmiştir.




Şekil 5.15. Bulanık sistem


Bu sözel değişkenlere ait üyelik dereceleri üçgen ve trapez üyelik fonksiyonlarıyla tanımlanmıştır (Şekil 5.16-5.18). Sistemin çıktısı olan stabilite sayısı, üçgen ve trapez üyelik fonksiyonları yardımıyla ve yedi farklı bulanık alt küme ile en düşük (ED), çok düşük (ÇD), düşük (D), orta (O), yüksek (Y), çok yüksek (ÇY) ve en yüksek (EY) sözel değişkenleri şeklinde tanımlanmıştır (Şekil 5.19).

Bulanık kural tabanı, sistemin girdilerine ait sözel değişkenlerin farklı kombinasyonlarından meydana gelen toplam 48 adet bulanık kuraldan oluşturulmuş (Ek 2); bulanık kuralların çıktılara ait kısımlarına karşılık gelen sözel değişkenlerin belirlenmesinde Van der Meer denklemlerinden yararlanılmıştır.


Ek 2'de örneği verilen kural tabanı içinde yer alan bulanık ilişkilere ait üyelik fonksiyonunun hesaplanmasında Larsen bulanık ilişki operatörü kullanılmış; sistemin girdilerine ait sözel değişkenler VE; bulanık kurallar ise birbirine VEYA operatörüyle bağlanmıştır. Durulaştırma işlemi ağırlık merkezi yöntemiyle yapılmıştır.




Şekil 5.16. Belirgin dalga yüksekliğine (H_s) ait bulanık alt kümeler



Şekil 5.17. Ortalama dalga periyoduna (T) ait bulanık alt kümeler




Şekil 5.18. Hasar seviyesine (S) ait bulanık alt kümeler



Şekil 5.19. Stabilite sayısına (N_s) ait bulanık alt kümeler


Stabilite sayılarının belirlenmesi amacıyla oluşturulan bulanık sistemin performansı Van der Meer denklemlerinden yararlanılarak farklı tasarım durumlarında test edilmiş örneğin $P=0,1$; $\cot \theta=2,0$; $N=3000$; $H_s=2,5$ ve $T=8,0$ s için farklı hasar seviyelerine ait stabilite sayıları, bulanık sistem ve Van der Meer denklemleriyle belirlenmiş ve iki farklı biçimde elde edilmiş stabilite sayıları arasındaki korelasyon katsayısı 0,593 olarak bulunmuştur. Bulanık sistemin performansını artırmak amacıyla, kural tabanı Van der Meer denklemleri ile Adeli-Hung (Tsoukalas and Uhrig, 1996) Algoritma (EK3) birlikte kullanılarak belirlenmiştir (Şekil 5.20). Bulanık kural tabanı EK 4'te verilmiştir.

Oluşturulan bulanık sistemde stabilite sayısına ait bulanık alt kümeler sabit alınmayıp farklı tasarım durumları için AHA ile yapılan sınıflandırma işlemine bağlı olarak değişik aralıklarda tanımlanmıştır.




Şekil 5.20. Adeli-Hung Algoritma ile kombine edilmiş bulanık sistem


Örneğin permeabilite katsayısının (P) 0,1; dalga sayısının (N) 3000 olması durumlarında eğim değerinin ($\cot \theta$) 2,0; 4,0 ve 6,0 değerleri için sırasıyla Şekil 5.21-23’de verilmiştir. Bulanık sistemin test aşamında, $P=0,1$; $\cot \theta=2,0$; $N=3000$; $H_s=2,5$ m ve $T=8,0$ s için farklı hasar seviyelerine ait stabilite sayıları, bulanık sistem ve Van der Meer denklemleriyle belirlenmiş ve iki farklı biçimde elde edilmiş stabilite sayıları arasındaki korelasyon katsayısı 0,847 olarak saptanmıştır. Dolayısıyla, bulanık kural tabanının çıktılarını oluşturan stabilite sayılarına ait bulanık alt kümelerin tanımlanmasında, Adeli-Hung algoritma ile Van der Meer denklemlerinin birlikte kullanılması (Şekil 5.20) bulanık sistemin performansını artıran bir faktör olmuştur.



Şekil 5.21. Adeli-Hung Algoritma ile kombine edilen bulanık sistem için stabilite sayısına (N_s) ait bulanık alt kümeler ($P=0,1$; $N=3000$; $\cot \theta=2,0$)




Şekil 5.22. Adeli-Hung Algoritma ile kombine edilen bulanık sistem için stabilite sayısına (N_s) ait bulanık alt kümeler ($P=0,1$; $N=3000$; $\cot \theta=4,0$)




Şekil 5.23. Adeli-Hung Algoritma ile kombine edilen bulanık sistem için stabilite sayısına (N_s) ait bulanık alt kümeler ($P=0,1$; $N=3000$; $\cot \theta=6,0$)

Taş dolgu dalgakıranların yapay zeka teknikleri ile tasarımına yönelik bu çalışmanın üçüncü bölümünde, stabilite sayıları, bulanık sinir ağları ile yapılmış ve ağı yapısı, P, S, N, $\cot \theta$ ve ϵ_m değerleri ağı girdileri, N_s değerleri ise ağı çıktısı olacak şekilde düzenlenmiştir. Girdi katmanına ait değişkenler, S eğrisi şeklindeki üyelik fonksiyonu kullanılarak, düşük (D) ve yüksek (Y) olmak üzere iki farklı kategoride sözel değişkenlerle tanımlanarak bulanıklaştırılmıştır (Şekil 5.24-28). Çıktı katmanına ait stabilite sayısı değerleri bulanıklaştırılmamış fakat 0,1 ve 0,9 değerleri arasında normalize edilmiştir.


Bulanık sinir ağının eğitilme ve test edilme aşamasında, daha önce ileri beslemeli denetimli sinir ağlarında belirtilen yaklaşım içinde toplam 554 veri kümesinin yaklaşık % 20'si eğitime geri kalan kısmı ise test aşamasında kullanılmıştır. Eğitime aşamasında, MGA eğitime algoritması kullanılmış ve her iterasyonda öğrenme oranı (adaptive learning rate) hata fonksiyonun değerine bağlı olarak değiştirilmiştir. Ara katmanlardaki hücre sayısı beş ve eğitime parametreleri, öğrenme oranı başlangıç değeri 0,004 ve momentum katsayısı 0,5 olarak belirlenmiştir.




Şekil 5.24. Bulanık sinir ağı için permeabilite katsayısına (P) ait bulanık alt kümeler




Şekil 5.25. Bulanık sinir ağı için hasar seviyesine (S) ait bulanık alt kümeler



Şekil 5.26. Bulanık sinir ağı için dalga sayısına (N) ait bulanık alt kümeler



Şekil 5.27. Bulanık sinir ağı için eğim ($\cot \theta$) değerine ait bulanık alt kümeler



Şekil 5.28. Bulanık sinir ağı için İribarren sayısına (ϵ_m) ait bulanık alt kümeler


Ara katmanlarda VE; çıktı katmanında ise VEYA tipi bulanık hücreler kullanılmıştır. Performans fonksiyonu karesel hataların ortalaması olarak alınmıştır. Uygun ağ yapısı ($x_{10}h_5y_1$) ve ortalama karesel hata değerinin (KH) iterasyon sayısına bağlı değişimi Çizelge 5.8’de özetlenmiştir. Test sonuçları korelasyon katsayıları (R) ile birlikte dağılım diyagramı halinde Şekil 5.29’da verilmiştir.

Bulanık sinir ağlarının eğitilme işlemi daha önce ileri beslemeli denetimli sinir ağlarının eğitilmesinde kullanılan düzenlenmiş veri tabanı ile de yapılmış ve düzenlenmiş veri kümesinin yaklaşık % 60 oranındaki ağın eğitilmesinde geri kalan kısmı ise test aşamasında kullanılmıştır. Bu aşamaya ait uygun ağ yapısı ($x_kh_sy_z$), momentum katsayısı, iterasyon sayısı ve karesel hataların ortalaması (KH) ve test aşamasına ait korelasyon katsayısı Çizelge 5.9’da birinci satırda ; dağılım diyagramı Şekil 30’da verilmiştir. Ayrıca, eğitme aşamasında kullanılan veri tabanı aynı şekilde oluşturulmuş ve ağın girdileri P, S, $\cot \theta$ ve ε_m değerlerinden meydana getirilmiş ve dalga sayısının (N) değerleri kullanılmamıştır. Bu aşamaya ait uygun ağ yapısı ve diğer parametreler Çizelge 5.9’da ikinci satırda verilmiştir.


Bulanık sinir ağlarının performansının geliştirilmesi amacıyla eğitme veri kümelerine belirli oranlarda rassal değişkenler ilave edilmiş ancak bu işlemler oluşturulan ağların mevcut performanslarının geliştirilmesine önemli oranda katkıda bulunmamıştır.

Çizelge 5.8. Düzenlenmemiş veri tabanı kullanılarak oluşturulan bulanık sinir ağı için eğitme aşamasına ait sonuçlar

Ağın Yapısı	İterasyon Sayısı	KH
$x_{10}h_5y_1$	100	0,020
$x_{10}h_5y_1$	1000	0,0194
$x_{10}h_5y_1$	2000	0,0190
$x_{10}h_5y_1$	3840	0,0096



Şekil 5.29. Girdileri P , $\cot \theta$, S , N , ε_m olan ve düzenlenmemiş veri tabanı kullanılarak eğitilen bulanık sinir ağı ile belirlenen stabilite sayıları için dağılım diyagramı



Şekil 5.30. Girdileri P , $\cot \theta$, S , N , ε_m olan ve düzenlenmiş veri tabanı kullanılarak eğitilen bulanık sinir ağı ile belirlenen stabilite sayıları için dağılım diyagramı

Çizelge 5.9. Düzenlenmiş veri tabanı kullanılarak oluşturulan Bulanık sinir ağına ait eğitime aşamasına ait sonuçlar

Ağ tipi ve girdi vektörü	Momentum katsayısı	İterasyon sayısı	KH	R
$x_{10}h_8y_1$ (P, S, N, $\cot \theta$ ve ε_m)	0,5	2500	0,0138	0,788
$x_8h_4y_1$ (P, S, $\cot \theta$ ve ε_m)	0,5	1000	0,0139	0,756

Yapay sinir ağları ve bulanık sinir ağları için, test aşamasında, elde edilen korelasyon katsayıları dikkate alındığında, her iki yapay zeka tekniğinin de kabul edilir düzeylerde tahminler yaptığı ve bu yöntemlerin korelasyon katsayılarının Van der Meer denklemleri mertebesinde olduğu görülmüştür. Özellikle düzenlemiş veri tabanı kullanılarak eğitilen ve girdi vektörü P, S, N, $\cot \theta$ ve ε_m değerlerinden meydana gelen ileri beslemeli denetimli sinir ağı Van der Meer denklemleriyle aynı seviyede performans göstermiştir.

Oluşturulan yapay zeka sistemlerinin, tasarım parametrelerinin değişimleri karşısındaki davranışları Van der Meer denklemleri de dikkate alınarak bir örnekle değerlendirilmiştir. Bütün sistemler için diğer tasarım parametreleri sabit iken, belirgin dalga yüksekliğinin 2,5 m; 5,5 m ve 8,5 m olması halinde stabilite sayılarının hasar seviyesine bağlı değişimi belirlenmiş; daha sonra $\cot \theta$ değerlerinin, diğer tasarım parametreleri sabit iken, 4,0 ve 6,0 olması durumunda stabilite sayılarının hasar seviyesine bağlı değişimleri saptanmıştır.

$P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8,0$ sn ve $H_s=2,5$ m değerleri için, yapay sinir ağı ile tahmin edilen stabilite sayısı değerleri Van der Meer denklemlerine kıyasla daha yüksek değerler vermiş; maksimum fark, hasar seviyesinin yaklaşık $S=10$ olduğu durum için, yaklaşık % 12 seviyesinde iken minimum fark yaklaşık % 2 düzeyinde hasar seviyesinin yaklaşık $S=2$ olması durumu için gözlenmiştir (Şekil 5.31).

Aynı koşullarda bulanık sistem için, maksimum fark yaklaşık % 114 seviyesine, (hasar seviyesi $S=1$), ulaşırken; minumum fark yaklaşık % 35 olarak (hasar seviyesi $S=24$) kaydedilmiştir (Şekil 5.32). Bu durumda bulanık sistem ($S=10-12$) hasar aralığında (kırılma tipinin değiştiği aralık), stabilitenin bir sıçrama yaparak düştüğünü hesaplayarak, yapay sinir ağı sistemi ile farklı bir davranış sergilemiştir. Stabilitate sayılarının bulanık sinir ağları ile tahmin edilmesi durumunda, maksimum fark hasar seviyesinin $S=1$ olması halinde yaklaşık % 71 olup minumum fark ise % 22 olarak hasar seviyesinin yaklaşık $S=9$ olması durumunda saptanmıştır (Şekil 5.33). Yukarıda belirtilen koşullarda aynı işlemler belirgin dalga yüksekliğinin 5,5 m ve 8,5 m olması durumları için de yapılmış sonuçlar Çizelge 5.10-12’de özetlenmiştir. Yapay zeka tekniklerinin Van der Meer denklemleri ile karşılaştırılması ayrıca Şekil 5.34-39’da verilmiştir.

Yapay sinir ağları ile yapılan tahminler düşük hasar seviyelerinde küçük farklar gösterirken; bulanık sinir ağları ve bulanık sistem ile yapılan tahminler Van der Meer denklemleri ile yapılan tahminlere göre küçük hasar düzeylerinde büyük farklılıklar göstermektedir. Yapay zeka teknikleri ile tahmin edilen stabilite sayıları Van der Meer denklemleri ile hesaplanan değerlerle korelasyon katsayılarına (R) bağlı olarak karşılaştırıldığında, kullanılan bütün yapay zeka tekniklerinin Van der Meer denklemlerine yakın eğilimler gösterdiği gözlenmiştir.

Çizelge 5.10. Stabilitate sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması ($H_s=2,5$ m)

Sistem	Fark (% maksimum)	S (Hasar)	Fark (% minumum)	S (Hasar)	R
Yapay Sinir Ağı	12,147	9,668	2,058	2,040	0,976
Bulanık Sistem	113,960	1	35,260	24	0,847
Bulanık Sinir Ağı	70,700	1	22,340	8,970	0,889

Çizelge 5.11. Stabilite sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması ($H_s=5,5$ m)

Sistem	Fark (% maksimum)	S (Hasar)	Fark (% minumum)	S (Hasar)	R
Yapay Sinir Ağı	15,384	24	-11,407	1,809	0,998
Bulanık Sistem	75,680	1	11,063	24	0,846
Bulanık Sinir Ağı	40,161	1	0,458	8,970	0,890

Çizelge 5.12. Stabilite sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması ($H_s=8,5$ m)

Sistem	Fark (% maksimum)	S (Hasar)	Fark (% minumum)	S (Hasar)	R
Yapay Sinir Ağı	17,021	24	-15,279	1,809	0,996
Bulanık Sistem	189,840	10,6	2,465	8,600	0,870
Bulanık Sinir Ağı	25,700	1	-9,900	8,974	0,891

Stabilite sayıların tahminine yönelik olarak oluşturulan yapay zeka uygulamaları, $P=0,1$; $N=3000$; $T=8,0$ sn ve $H_s=2,5$ m değerleri için yukarıda belirtilen işlemlere ilave olarak eğim ($\cot \theta$) değerlerinin 4,0 ve 6,0 olması durumu için de yapılmış (Şekil 5.40-45) sonuçlar Çizelge 5.13-14'de verilmiştir. Bu aşamada da, korelasyon katsayılarına bağlı olarak bütün yapay zeka tekniklerinin Van der Meer denklemlerine yakın eğilimlere sahip olduğu gözlenmektedir.

Yapay zeka tekniklerinin tasarım parametrelerinin değişimi karşısındaki davranışlarına bağlı olarak özellikle yapay sinir ağının, Van der Meer denklemleri ile birbirine çok yakın davranışlar sergilediği gözlenmektedir. Her iki yaklaşımın karşılaştırılmasında korelasyon katsayılarının çok yüksek değerler aldığı (Çizelge 5.10-14) söylenebilir: Örnek olarak, koruma tabakası eğiminin ($\cot \theta$) 4,0; permeabilite katsayısının (P) 0,1; belirgin dalga yüksekliğinin (H_s) 2,5 m, dalga sayısının (N) 3000 ve dalga periyodunun (T) 8,0 sn olduğu durumda, Van der Meer denklemleri ve yapay sinir ağı ile elde edilen stabilite sayılarının uyumu Şekil 5.40'ta gözlenmektedir. Belirgin dalga yüksekliğinin, permeabilite katsayısının küçük

sayılabilecek değerler aldığı ve eğimin ($\cot \theta$) 2,0 ve 6,0 arasında değiştiği tasarım koşullarında, her iki yaklaşımın benzeşimi dikkat çekicidir.


Çizelge 5.13. Stabilite sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması ($\cot \theta=4,0$)

Sistem	Fark (% maksimum)	S (Hasar)	Fark (% minimum)	S (Hasar)	R
Yapay Sinir Ağı	4,357	13,713	-4,546	2,271	0,996
Bulanık Sistem	113,968	1	33,651	24	0,848
Bulanık Sinir Ağı	25,326	1	-16,475	13,135	0,906


Çizelge 5.14. Stabilite sayılarına (N_s) göre Van der Meer denklemlerinin yapay zeka teknikleri ile karşılaştırılması ($\cot \theta=6,0$)

Sistem	Fark (% maksimum)	S (Hasar)	Fark (% minimum)	S (Hasar)	R
Yapay Sinir Ağı	17,473	1	3,867	5,623	0,987
Bulanık Sistem	113,966	1	31,838	24	0,888
Bulanık Sinir Ağı	25,326	1	-16,475	13,135	0,890


Van der Meer denklemlerinden elde edilen sonuçlarla yapay zeka teknikleri genel olarak, karşılaştırıldığında belirgin farklılık, bütün tasarım koşullarında özellikle hasar seviyesinin artmasıyla Van der Meer denklemleri ve yapay zeka teknikleri arasındaki farkın artışı şeklinde gözlenmiştir. $S=1$ ve $S=2$, Hudson denkleminde % (0-5) aralığındaki yapıda hasar oluşmaması durumunu yansıtmaktadır ve Türkiye’de uygulamada en çok seçilen tasarım değerleridir. Bu hasar aralığında yapay sinir ağı Van der Meer denklemlerine daha yakın bir davranış sergilemiştir. Yapay sinir ağları ve bulanık sinir ağları, genel olarak parametrik değişimlere duyarlılık açısından, birbirine yakın eğilimler (artma ya da azalma şeklinde) göstermesine karşın benzer davranışlar bulanık sistemde gözlenmemiştir. Bu durum, yapay sinir ağlarının ya da eğitilebilen sistemlerin modelleyebilme (function approximation) yeteneği açısından bulanık sistemlerden genellikle daha başarılı olduğu (Kosko, 1997) dikkate alındığında, öğrenebilen sistemlerle statik sistemler arasındaki farkı ortaya koymaktadır.




Şekil 5.31. Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=2,5$ m; $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8$ sn)




Şekil 5.32. Bulanık sistem ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=2,5$ m; $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8$ sn)




Şekil 5.33. Bulanık sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=2,5$ m; $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8$ sn)




Şekil 5.34. Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=5,5$ m; $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8$ sn)




Şekil 5.35. Bulanık sistem ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=5,5$ m; $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8$ sn)




Şekil 5.36. Bulanık sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=5,5$ m; $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8$ sn)




Şekil 5.37. Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=8,5$ m; $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8$ sn)




Şekil 5.38. Bulanık sistem ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=8,5$ m; $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8$ sn)




Şekil 5.39. Bulanık sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($H_s=8,5$ m; $P=0,1$; $\cot \theta=2,0$; $N=3000$; $T=8$ sn)




Şekil 5.40. Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=4,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)




Şekil 5.41. Bulanık sistem ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=4,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)




Şekil 5.42. Bulanık sınır ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=4,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)



Şekil 5.43. Yapay sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=6,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)



Şekil 5.44. Bulanık sistem ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=6,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)



Şekil 5.45. Bulanık sinir ağı ile elde edilen stabilite sayılarının hasar seviyesine bağlı değişimi ($\cot \theta=6,0$; $P=0,1$; $H_s=2,5$ m; $N=3000$; $T=8$ sn)

Ancak, burada özellikle eğitilebilen bir sistem kurulamaması halinde belirsizliklerin işlenebilmesi açısından karmaşık sistemlerin modellenenebilmesine bulanık sistemlerin önemli katkılar getireceği ve bulanık kural tabanlarının oluşturulmasında daha ayrıntılı ve geniş bir bilgi tabanından yararlanılmasının daha yetkin sonuçların elde edilmesini sağlayabileceği gözönüne alınmalıdır.


Yukarıda verilen karşılaştırmalara ilave olarak yapay sinir ağı ile Van der Meer denklemleri tasarım parametrelerine bağlı olarak da karşılaştırılmıştır. Sırasıyla stabilite sayıları (N_s) ile permeabilite katsayısı (P), Iribarren sayısı (ϵ_m), dalga sayısı (N) ve eğim ($\cot \theta$) arasındaki ilişki diğer parametreler sabit iken belirlenmiştir. Genel olarak sözkonu parametrelerle stabilite sayıları arasında Van der Meer ve yapay sinir ağları birbirine yakın davranışlar göstermiştir: Permeabilite katsayısının düşük değerlerinde yapay sinir ağı, Van der Meer denklemine kıyasla daha düşük stabilite sayıları verirken; permeabilite katsayısındaki artışla farkların azaldığı gözlenmiştir (Şekil 5.46). Iribarren sayısının 3,5 ve daha küçük olduğu durumlarda yapay sinir ağı ile elde edilen stabilite sayıları daha küçük değerler alırken, Iribarren sayısının 3,5 ve daha büyük değerlerinde ise Van der Meer denklemi daha küçük

stabilite sayıları vermiştir (Şekil 5.47). Dalga sayısının 3000'e kadar olan tüm değerleri için Van der Meer denklemi ile elde edilen stabilite sayıları daha yüksek değerler göstermiştir (Şekil 5.48). Her iki yaklaşımla bulunan stabilite sayıları arasındaki fark eğimin 1,5-3,5 değerleri arasında olması halinde artarken; 3,5 ve 5,5 arasındaki eğim değerlerinde azalmıştır. Eğimin 5,5 değerinden büyük olması durumunda yapay sinir ağının daha düşük stabilite sayıları verdiği gözlenmiştir (Şekil 5.49).


Tasarım parametrelerinin her aşamada sabitlenmesi aynı koşulları sağlayan yeterli sayıda deney verisine ulaşılmasını engellediğinden, Şekil 5.46-49'da özetlenen sonuçlar gerçek stabilite sayılarının noktalanması ile desteklenememiştir. Bu nedenle, yapay sinir ağının eğitime ya da test aşamasında kullanılmayan ve Van der Meer (1988) tarafından verilen deney verilerinden rassal olarak seçilen ve toplam 20 girdi vektöründen oluşan veri grubundan (Çizelge 5.15) yararlanılarak her iki yaklaşım istatistiksel parametrelere bağlı olarak karşılaştırılmıştır: İki farklı biçimde belirlenen stabilite sayılarına ait ortalama, standart sapma ve değişim katsayısından oluşan istatistiksel parametreler ile korelasyon katsayıları dikkate alındığında, yapay sinir ağına ait sonuçların gerçek veri grubunu istatistiksel olarak daha fazla temsil ettiği gözlenmiştir (Çizelge 5.16).

Çizelge 5.15. Rassal olarak seçilen deney verilerine ait değişim aralıkları


Değişken	Maksimum	Minimum
Permeabilite katsayısı (P)	0,60	0,10
Eğim (Cot θ)	6,00	2,00
Stabilite sayısı (N_s)	4,30	1,2
İribarren sayısı (ϵ_m)	6,10	0,80
Hasar seviyesi (S)	29,1	1,20
Dalga sayısı (N)	3000	1000




Şekil 5.46. Permeabilite katsayısı (P) ile stabilite sayısı (N_s) arasındaki ilişkinin yapay sinir ağı ve Van der Meer denklemleri için karşılaştırılması ($\cot \theta=2,0$; $\epsilon_m=1,0$; $S=2,0$; $N=2000$)



Şekil 5.47. Iribarren sayısı (ϵ_m) ile stabilite sayısı (N_s) arasındaki ilişkinin yapay sinir ağı ve Van der Meer denklemleri için karşılaştırılması ($\cot \theta=2,0$; $P=0,1$; $S=2,0$; $N=2000$)



Şekil 5.48. Dalga sayısı (N) ile stabilite sayısı (N_s) arasındaki ilişkinin yapay sinir ağı ve Van der Meer denklemleri için karşılaştırılması ($\cot \theta=2,0$; $\epsilon_m=1,0$; $S=2,0$; $P=0,1$)



Şekil 5.49. Eğim ($\cot \theta$) ile stabilite sayısı (N_s) arasındaki ilişkinin yapay sinir ağı ve Van der Meer denklemleri için karşılaştırılması ($P=0,1$; $\epsilon_m=7,0$; $S=2,0$; $N=2000$)

Çizelge 5.16. Yapay sinir ağı ve Van der Meer denklemleri kullanılarak belirlenen stabilite sayıları ile deney verilerine ait stabilite sayıları için istatistiki parametrelerin değişimi

Model	Ortalama	Standart sapma	Değişim katsayısı	R
Gerçek veri	2,305	0,748	0,324	-
VDM	2,323	0,603	0,259	0,947
YSA	2,316	0,756	0,326	0,968

Mersin yat limanı ana dalgakıranına ait koruma tabakası için stabilite sayısı Van der Meer denklemlerine ilave olarak eğitilen yapay ve bulanık sinir ağları ile birlikte bulanık sistem kullanılarak belirlenmiştir. Tasarım sırasında gözönüne alınacak belirgin dalga yüksekliği ve periyodu değerleri farklı yineleme süreleri için Şekil 5.2’de tanımlanan denklem yardımıyla belirlenmiş olup dalga periyodlarının hesaplanmasında bölge için kabul edilebilen $H_0/L_0=0.042$ eşitliğinden yararlanılmıştır. Eğim değeri ($\cot \theta$), dalga sayısı (N) sırasıyla 2,5 ve 2000 olarak alınmıştır (Balas, 1998). Hesaplanan belirgin dalga yükseklikleri ve periyodları, yineleme sürelerine bağlı olarak Çizelge 5.17’de verilmiştir. Nominal taş çapları (D_{n50}) ve ağırlıkları (W) iki farklı hasar seviyesinde ve 25, 50 ve 100 yıllık yineleme süreleri için Van der Meer denklemi ve en yüksek performansa (korelasyon katsayılarına) sahip yapay zeka teknikleri kullanılarak hesaplanmış ve sonuçlar Çizelge 5.18-20’de özetlenmiştir.

Çizelge 5.17. Mersin yat limanı tasarımı için hesaplanmış farklı yineleme sürelerine ait belirgin dalga yüksekliği ve periyodları

Yineleme Süresi (T_r)	25	50	100
Belirgin Dalga yüksekliği (H_s) (m)	4,543	4,982	5,418
Dalga Periyodu (T) (sn)	8,327	8,720	9,094

Çizelge 5.18. Mersin yat limanı ana dalgakıran koruma tabakası için Van der Meer denklemi ve yapay zeka teknikleri ile elde edilen taş çapları ve ağırlıkları ($T_r=25$ yıl)

Model	S=2		S=10	
	D_{n50} (m)	W (ton)	D_{n50} (m)	W (ton)
Yapay Sinir Ağı (YSA)	1,307	6,027	0,982	2,562
Bulanık Sistem (BS)	2,283	32,166	1,773	15,050
Bulanık Sinir Ağı (BSA)	1,243	5,189	1,164	4,265
Van der Meer Denklemi (VDM)	1,381	7,111	1,004	2,737

Çizelge 5.19. Mersin yat limanı ana dalgakıran koruma tabakası için Van der Meer denklemi ve yapay zeka teknikleri ile elde edilen taş çapları ve ağırlıkları ($T_r=50$ yıl)


Model	S=2		S=10	
	D_{n50} (m)	W (ton)	D_{n50} (m)	W (ton)
Yapay Sinir Ağı (YSA)	1,433	7,951	1,077	3,380
Bulanık Sistem (BS)	2,486	41,529	1,931	19,441
Bulanık Sinir Ağı (BSA)	1,363	6,842	1,277	5,625
Van der Meer Denklemi (VDM)	1,514	9,380	1,101	3,611

Çizelge 5.20. Mersin yat limanı ana dalgakıran koruma tabakası için Van der Meer denklemi ve yapay zeka teknikleri ile elde edilen taş çapları ve ağırlıkları ($T_r=100$ yıl)


Model	S=2		S=10	
	D_{n50} (m)	W (ton)	D_{n50} (m)	W (ton)
Yapay Sinir Ağı (YSA)	1,558	10,228	1,172	4,348
Bulanık Sistem (BS)	2,740	55,580	2,128	26,012
Bulanık Sinir Ağı (BSA)	1,482	8,801	1,389	7,235
Van der Meer Denklemi (VDM)	1,647	12,067	1,198	4,645

Farklı tekniklerle elde edilen sonuçlar karşılaştırıldığında Van der Meer denklemleri ile yapay ve bulanık sinir ağları iki farklı hasar seviyesinde ($S=2$ ve $S=10$) birbirine yakın sonuçlar vermiştir (Şekil 5.50-51). Hasar seviyesinin $S=2,0$ olması halinde Van der Meer denklemleri ile yapay ve bulanık sinir ağları kullanılarak belirlenen taş çapları arasındaki maksimum fark yinelenme süresinin 100 yıl olduğu durumda sırasıyla % 5,4 ve % 10 olup (Şekil 5.50); hasar seviyesinin $S=10$ olması halinde bu oranlar % 2,17 ve % 15,9 olarak hesaplanmıştır (Çizelge 5.20). Bulanık sistemle belirlenen taş çapları ise Van der Meer denkleminde kıyasla % 60-80 arasında fark göstermiştir (Şekil 5.51).

Mersin Yat Limanı için seçilen ekonomik ömür $L=50$ yıl olup (Balas, 1998) bu süre için hesaplanan taş çapları ve ağırlıkları Çizelge 5.19'da özetlenmiştir. Hasar seviyesinin $S=2$ değerinde Van der Meer denklemi yapay ve bulanık sinir ağlarına kıyasla sırasıyla yaklaşık % 5,0 ve %10,0 oranlarında daha yüksek taş çapları verirken; hasar seviyesinin $S=10$ olması bu farkların sırasıyla yaklaşık % 2,0 ve 16,0 olmasına neden olmuştur (Şekil 5.50-51). Aynı koşullarda bulanık sistem ile tahmin edilen taş çaplarına ait farklar, $S=2$ ve $S=10$ hasar seviyeleri için sırasıyla % 64 ve 75 olarak hesaplanmıştır. Yapay sinir ağı, taş çapları açısından Van der Meer denklemlerine yakın sonuçlar vermiştir. Düşük ($S=2$) ve yüksek ($S=10$) hasar seviyeleri için hesaplanan taş ağırlıkları arasındaki fark, yapay sinir ağı kullanıldığında yaklaşık % 25, Van der Meer denklemi kullanıldığında yaklaşık % 27 olmuştur (Şekil 5.50-51). Taş ağırlıkları açısından, her iki yaklaşım arasında $S=10$ hasar seviyesi için yaklaşık % 7'lik bir fark bulunmaktadır. Hasar seviyesinin seçimi, taş dolgu dalgakıranların maliyetini değişik biçimlerde etkilediği için önemlidir: Hasar seviyesinin düşük seviyelerde seçilmesi yapının ilk maliyetini artırırken; yüksek hasar seviyeleri yapının bakım ve onarım maliyetlerinde artışa neden olmaktadır. Yinelenme süresinin seçimi ise, kıyı yapısı ve koruduğu tesis (nükleer santral, endüstri limanı, yat limanı, deniz deşarjı, balıkçı barınağı vb.) için kabul edilen risk düzeyinin bir fonksiyonudur. Bu nedenle, ön tasarım aşamasında maliyet ve risk optimizasyonu ile taş çaplarının belirlenmesi yapının ekonomik ve emniyetli olarak tasarlanmasını sağlayacaktır.



Şekil 5.50. Mersin Yat Limanı için Hasar seviyesinin $S=2$ olması halinde Van der Meer Denklemleri ve yapay zeka teknikleri ile belirlenen nominal taş çaplarının yineleme sürelerine bağlı değişimi



Şekil 5.51. Mersin Yat Limanı için Hasar seviyesinin $S=10$ olması halinde Van der Meer Denklemleri ve yapay zeka teknikleri ile belirlenen nominal taş çaplarının yineleme sürelerine bağlı değişimi

5.3. Taş Dolgu Dalgakıranlarda Genetik Algoritma ile Güvenirlik Analizi

Kıyı yapısı projeleri, dayanım ve olası yük değerlerine bağlı yüksek derecedeki belirsizlikleri içerir ve bu belirsizlikler, risk yönetim modelleri içerisinde gözönüne alınır (Williams et. al., 1998). Belirsizliklerin etkisiyle yapının performansında gözlenecek olumsuzluklar yapının risk seviyesini dolayısıyla güvenirliliğini etkiler. Güvenirlik, yapının belirlenen ekonomik ömrü boyunca beklenen performansını yerine getirebilmesidir ve olasılık yöntemleriyle (II. ve III. seviye yöntemler) belirlenir. Yapıların deterministik olarak projelendirildiği durumlarda ise belirsizlikler gözönüne alınmaz ve yapının güvenirliliğinin ölçüsü emniyet katsayıları ile ortaya konur. Ancak, projelendirme ile birlikte güvenirliliğin de tahmin edilebilmesi için yük ve dayanım değişkenlerine ait belirsizliklerin de (Bölüm 1) dikkate alındığı olasılık yöntemlerinden yararlanılması gerekir.

Bir mühendislik sisteminin güvenliği, bir limit duruma karşılık gelen, güvenirlilik ya da yıkılma olasılığı ile değerlendirilir. Yapısal güvenirliliğin tahmininde uygulanan ve belirsizliklerin dikkate alındığı ikinci düzey olasılık yöntemlerinde, yıkılma olasılığı güvenirlilik indeksine bağlı olarak belirlenmektedir. Bu tür yaklaşık olasılık yöntemlerinde, yapının güvenirlilik indeksi performans fonksiyonunun "limit durumu" için indirgenmiş tasarım değişkenleri sisteminin optimizasyonu yoluyla "en olası yıkım (göçme) noktasına" bağlı olarak belirlenmektedir.

Bu çalışmada, taş dolgu dalgakıranlar için güvenirlilik indeksi ikinci düzey olasılıksal yöntemlerle birlikte genetik algoritma ile belirlenmiş ve sonuçlar karşılaştırılmıştır. Taş dolgu dalgakıranlar için "limit durum" belirlenen bir hasar seviyesinin yapının tümüyle yıkılmasına neden olmayacak, ancak performansını yerine getiremeyecek şekilde aşılması hali olarak tanımlanmıştır (Ergin and Balas, 1998).


Bir yapının emniyeti (güvenirliliği) yapının dayanımı ile birlikte yapıya etkiyebilecek yüklerin bileşik etkisine bağlıdır. Herhangi bir hasar biçimi için oluşturulacak performans fonksiyonu, yük ve dayanım değişkenlerini içerir ve bu değişkenler rassal değişkenler olarak kabul edilirler. Yük değişkenleri, yapıya etkiyen yük veya

yüklere karşılık gelirken; dayanım değişkenleri, yapıyı oluşturan eleman veya elamanların dayanım/yük taşıma kapasitelerini ifade etmektedir ve yapının performansı, matematiksel olarak bu değişkenlere ($\mathbf{x}$) bağlı olarak kurulan performans fonksiyonu $g(\mathbf{x})=g(\text{yük değişkenleri, dayanım değişkenleri})$ ile ifade edilir; tasarım değişkenlerinin vektörel bileşkesi yapının ya da sistemin performansının (davranışının) bir ölçüsüdür. Taş dolgu dalgakıranlar için esas yük değişkeni tasarım koşullarına (fırtına, tsunami veya gel-git) bağlı olarak belirlenen dalga yüksekliği olup genel olarak yapısal sistemi tanımlayan değişkenler (taş çapı, eğim vb) dayanım değişkenleri olarak adlandırılırlar (Balas and Balas, 2002).

Vektörel olarak $\{X\}$ şeklinde tanımlanabilen tasarım değişkenleri yardımıyla, limit durumdaki yıkılma fonksiyonu aşağıdaki şekilde verilebilir:

$$g(X_1, X_2, X_3 \dots X_n) = 0 \quad (5.5)$$

Geometrik olarak bu eşitlik yıkılma yüzeyinine karşılık gelmekte ve $g \leq 0$ için yıkılma bölgesini; $g > 0$ için ise emniyetli bölgeyi tanımlamaktadır. (5.5) nolu eşitlikle tanımlanan limit durum yıkılma yüzeyi olarak da tanımlanır ve “dönüştürülmüş değişkenler takımı” için yıkılma bölgesini ($g \leq 0$) güvenli bölgeden ($g > 0$) ayıran çok boyutlu bir yüzeye karşılık gelir. Şekil 5.52’de iki değişkenli bir performans fonksiyonunun değişimi örnek olarak verilmiştir. Limit durum yüzeyinin koordinat sisteminin başlangıç noktasından olan uzaklığı (β) güvenli bölgeyi belirler ve bu uzaklığın minimum olduğu nokta yıkılma yüzeyi olarak tanımlanır. Yapının güvenilirlik indeksi olarak da tanımlanan sözkonusu minimum uzaklık, en olası yıkılma noktası olarak kabul edilir ve yapının güvenilirliğinin belirlenmesinde ölçüt alınır. Performans fonksiyonları genellikle doğrusal değildir ve bu nedenle yıkılma yüzeyi konveks veya konkav bir özellik gösterir (Şekil 5.52).



Şekil 5.52. İki değişkenli performans fonksiyonu için güvenirlilik indeksi

Taş dolgu dalgakıranların projelendirilmesinde yük ve dayanım değişkenleri arasında stabilite koşulunu veren yarı-deneysel eşitliklerden yararlanılmakta olup Hudson (1953) eşitliği yaygın olarak kullanılan eşitliklerden biridir. Limit durum için yıkılma fonksiyonları ve kullanılan parametreler Hudson eşitliği için sırasıyla g : limit durum fonksiyonu, Y : eşitlikteki belirsizliklere karşılık gelen stokastik değişken, H_s : yapının topuğundan itibaren belirgin dalga yüksekliği (m), θ : koruma tabakasının eğimi, D_{n50} : koruma tabakasının nominal taş çapı (m), K_D : hasar seviyesine bağlı boyutsuz stabilite katsayısı, Δ : koruma tabakasına ait göreceli taş yoğunluğu olmak üzere:

$$g = Y \Delta D_{n50} (K_D \cot \theta)^{1/3} - H_s \quad (5.6)$$

olarak verilebilirler. Bu durumda, yıkılma olasılığı (P_f) aşağıdaki şekilde ifade edilir:

$$P_f = \iiint_{g \leq 0} \dots \int f_{X_1, \dots, X_n}(x_1, \dots, x_n) dx_1, \dots, dx_n \quad (5.7)$$

Burada, f_{xi} : performans değişkenlerine ait olasılık yoğunluk fonksiyonları olarak tanımlanabilir. Ancak, bu tür yaklaşımlarda güvenirliliğin ($P_r=1-P_f$) belirlenebilmesi için performans fonksiyonuna ait değişkenlerin ortak olasılık yoğunluk fonksiyonlarının belirlenmesi gerekmekte ancak pratikte, çoğunlukla istatistikî bilgiler ortalama ve standart sapma gibi parametrelerle sınırlı kalmaktadır. Bu nedenle üst seviye (III. düzey) olasılık yaklaşımlarının yerine ikinci düzey yaklaşımlar daha yaygın olarak kullanılmaktadır.

İkinci düzey olasılık yöntemlerden ikinci moment yaklaşımında, güvenirlilik indeksi (β), “dönüştürülmüş değişkenler takımı” olan Z için yıkım yüzeyi üzerindeki herhangi bir noktanın indirgenmiş eksen uzayının başlangıç noktasına olan uzaklığını tanımlayan amaç fonksiyonunun, $g(Z)=0$ kısıtlayıcı koşulunda, optimizasyonu ile iteratif olarak belirlenir. Bu koşullarda bulunan, uzaklık değeri, en olası yıkım noktasını temsil etmektedir.

$$\beta = \min(Z^T Z)^{1/2} \quad (5.8)$$

$$Z \in G \quad (5.9)$$

$$G = \{ Z \mid g(Z)=0 \} \quad (5.10)$$

İkinci moment birinci aşama yaklaşımında, güvenirlilik indeksi performans fonksiyonunun, birinci aşama (Taylor serisi açılımıyla) yaklaşık ifadesine göre doğrusallaştırılmış yıkılma yüzeyi üzerinde (Şekil 5.52), iteratif olarak belirlenir ve (*) indisi yıkım yüzeyindeki değerleri belirtmek koşuluyla aşağıdaki şekillerde ifade edilebilir (Melchers, 1999).

$$G \approx \sum_{i=1}^n (Z_i - Z_i^*) \left(\frac{\partial g}{\partial Z_i} \right)^* \quad (5.11)$$

$$Z_i^* = -\alpha_i^* \beta \quad i = 1, 2, \dots, n \quad (5.12)$$

$$\alpha_i^* = \frac{(\frac{\partial g}{\partial Z_i})^*}{(\sum_{i=1}^n \frac{\partial g}{\partial Z_i})^{*2})^{1/2}} \quad (5.13)$$

Burada, α_i yönsel kosünüs değerleri ve n: temel değişken sayısıdır.

Bu çalışmada birinci merteye ikinci momet yaklaşımıyla güvenilirlik indeksi, Mersin yat limanı için verilen parametreler kullanılarak (Balas, 1998) tahmin edilmiştir. Değişkenler standart değişkenlere indirgenmiş; belirgin dalga yüksekliği “Rosenblatt dönüşümü” ile eşdeğer normal dağılıma modellenmiş; K_D katsayısı 1,0 olarak alınmıştır. Değişkenlere ait istatistiki özellikler Çizelge 5.21’de verilmiştir. Güvenirlik indeksi, ikinci moment yöntemi ile doğrudan ve iteratif olarak belirlenmiştir. Yıkılma olasılıkları ve değişkenlerin en olası göçme yüzeyini temsil eden değerleri Çizelge 5.22’nin birinci ve ikinci satırlarında her iki yöntem için verilmiştir.

Çizelge 5.21. Tasarım değişkenlerine ait istatistiki özellikler

Değişken (x_i)	Olasılık Dağılımı	Ortalama (μ_{xi})	Standart sapma (σ_{xi})
Y	Normal	1,0	0,18
D_{n50}	Normal	1,44 m	0,06 m
H_s	Fisher-Tippet I	2,88 m	0,96 m
Δ	Normal	1,62	0,05
Cot θ	Normal	2,50	0,30

Çizelge 5.22. Değişik yöntemlerle elde edilen yıkılma olasılıkları ve tasarım değişkenlerinin yıkılma yüzeyine ait değerleri

Yöntem	β	P_f (%)	$1-P_f$ (%)	Y	D_{n50} (m)	Δ	$\text{Cot } \theta$	H_s (m)
İkinci Moment (Doğrudan çözüm)	0,4078	34,17	65,83	0,962	1,618	1,437	2,485	3,029
İkinci Moment (İteratif çözüm)	0,4040	34,31	65,69	0,964	1,618	1,437	2,487	3,037
Genetik Algoritma	0,0057	49,77	50,23	0,999	1,439	1,620	2,500	2,878
Gradyen Azalma	0,0012	49,95	50,05	0,999	1,620	1,440	2,500	2,880
Tepe Tırmanması	0,0033	49,87	50,13	1,000	1,620	1,440	2,499	2,880
Monte Carlo Benzeşimi	-	45,74	54,26	-	-	-	-	-


Çalışmanın ikinci kısmında eşitlik (5.11) ve (5.13) ile tanımlanan optimizasyon problemi genetik algoritma kullanılarak yapılmıştır. Başlangıç topluluğu değişkenlere ait istatistiki bilgiler ve olasılık dağılımları kullanılarak rassal şekilde oluşturulmuş; başlangıç topluluğundaki dizi sayısı 30 olarak belirlenmiş ve diziler onluk sisteme göre kodlanmıştır. Çaprazlama oranı 0,8; mutasyon oranı 0,001 seçilmiştir. Seçilim işleminde, rulet çemberi seçilim mekanizması kullanılmıştır. İterasyon sayısı 500 olarak alınmıştır.

Uygunluk fonksiyonu, amaç ve kısıtlılık fonksiyonlarına bağlı olarak aşağıdaki şekilde tanımlanmıştır.


$$F = K - \beta(Z) - C (g(Z))^r \quad (5.14)$$

Burada, K değeri yardımıyla minimizasyon problemi maksimizasyon problemine dönüştürülmüş ve K değer 100 olarak seçilmiştir. Ceza fonksiyonunun parametreleri olan r değeri 2,0 alınmış (Schilling and Harris, 2000); C değeri $C = (P_o / g_o)^r$ eşitliği (Jenkins, 1993) kullanılarak 10,0 olarak hesaplanmıştır. Burada P_o : kısıtlılık fonksiyonunun g_o değerine karşılık uygulanmak istenen ceza değeridir.

Genetik algoritma uygulamasına ait iterasyon sonuçları, uygunluk fonksiyonu değerlerine ve güvenilirlik indeksinin değişimine bağlı olarak Şekil 5.53-54’de verilmiştir. Yıkılma olasılıkları ve değişkenlerin en olası göçme yüzeyini temsil eden değerleri ise Çizelge 5.22’de üçüncü satırda verilmiştir.



Şekil 5.53. Uygunluk fonksiyonu değerlerinin iterasyon sayısına bağlı değişimi




Şekil 5.54. Güvenirlik indeksi değerlerinin genetik algoritma için iterasyon sayısına bağlı değişimi

Genetik algoritma ile elde edilen çözüm ayrıca amaç fonksiyonunun $(f(Z)+C(g(Z)))^r$ gradyen azalma (gradient descent) algoritması ile minimizasyonu yapılarak kontrol edilmiştir. Bu aşamada, başlangıç noktaları genetik algoritmada uygulanan yaklaşım içinde tasarım değişkenlerinin olasılık dağılımlarına göre rassal olarak oluşturulmuş; adım aralığı (step size) 0,01 alınmış ve iterasyona amaç fonksiyonu değerinin küçük salınımlar yaptığı noktaya (iterasyon sayısı 273) kadar devam edilmiştir. Gradyen azalma algoritması ile elde edilen yıkılma olasılıkları ve değişkenlerin en olası göçme yüzeyini temsil eden değerleri Çizelge 5.22’de dördüncü satırda verilmiştir. Sözkonusu minimizasyon işlemi tepe tırmanması (hill climbig) yöntemiyle (Polgar et. al., 2000; Tsang and Voudouris, 1997; Gonzalez and Perez, 2001) de yapılmış ve sonuçlar Çizelge 5.22’nin beşinci satırında özetlenmiştir.

Yapının yıkılma olasılığı, Monte Carlo Benzeşimi (Melchers, 1999) ile belirlenmiş ve bu aşamaya ait sonuçlar Çizelge 5.22’nin altıncı satırında verilmiştir. Monte Carlo Benzeşimi yönteminde iterasyon sayısı 10 000 olarak alınmıştır. Rassal bir şekilde olasılık dağılımlarına bağlı olarak atanan tasarım değişkenlerinin değerleri yıkılma olasılığını vermektedir. Yıkılma olasılığı, performans fonksiyonunun sıfır ve daha küçük değerler alma sayısının toplam gözlem sayısına oranıdır. İterasyon sürecinde, performans fonksiyonunun aldığı değerlerin gözlenme sıklığı Şekil 5.55’de verilmiştir. Burada, yıkılma olasılığı, sıfır ve daha küçük değerlerin gözlenme sıklığı olarak belirtilmiştir.


Optimizasyon problemlerinde, tasarım değişkenlerine bağlı olarak amaç fonksiyonunun belirli aralıklarda alabileceği değerlerin grafiksel olarak ortaya konması ve fonksiyonun global ya da yersel maksimum veya minimum noktalarının belirlenmesi, ulaşılan çözümlerin gerçekleşmesi açısından kolaylaştırıcı bir unsurdur. Fonksiyon yüzeyinin değişim grafiği Şekil 5.56’da, gösterim amacıyla dalga yüksekliği ve eğim değerleri dışındaki tasarım değişkenlerinin sabit alındığı durum için sunulmuştur. Grafikte sabit alınan değişkenler, genetik algoritma optimizasyonu sonunda ulaşılan minimum değerlerini taşımaktadırlar. Başka bir deyişle, Şekil 5.56’da çözümü gerçekleştiren amaç

fonksiyonu $(\beta(Z)+C(g(Z))^T)$ belirgin dalga yüksekliği ve eğim değerlerinin $[-1,1]$ aralığındaki değişimi için Y , D_{n50} ve Δ değişkenlerinin minimum (genetik algoritma ile elde edilen yıkılma yüzeylerindeki dönüştürülmüş değerlerini) alması durumunu ifade etmektedir.




Şekil 5.55. Mersin yat limanına için uygulanmış Monte Carlo Benzeşimi sonucunda elde edilmiş performans fonksiyonu değerlerinin gözlenme sıklığı


Genetik algoritma uygulamasında ortaya çıkan en uygun çözümlerin (dizilerin) belirgin dalga yüksekliği ve eğim değerleri için değişimi, Şekil 5.56’de verilen amaç fonksiyonunun eş değer (equal contour) aralıkları için iki boyutlu fonksiyon yüzeyi üzerinde noktalanmasıyla Şekil 5.57’de sunulmuştur. Ayrıca, gradyen azalma algoritması ile iteratif olarak elde edilen çözümlerin belirgin dalga yüksekliği ve eğim değerleri için değişimi, amaç fonksiyonunun eş değer aralıkları için iki boyutlu fonksiyon yüzeyi üzerinde noktalanmasıyla Şekil 5.58’de verilmiştir. İkinci moment yöntemi ile bulunan yıkılma yüzeyine ait belirgin dalga yüksekliği ve eğim değeri ise Şekil 5.59’da noktalanarak gösterilmiştir.




Şekil 5.56. Amaç fonksiyonunun belirgin dalga yüksekliği ve eğim değerlerine bağlı değişimi



Şekil 5.57. Genetik algoritma ile bulunan en uygun dizilerin belirgin dalga yüksekliği ve eğim değerleri için dağılımı



Şekil 5.58. Gradyen azalma algoritması ile iteratif çözümün dalga yüksekliği ve eğim değerleri için değişimi



Şekil 5.59. İkinci moment yöntemi ile iteratif olarak elde edilen yıkılma yüzeyi için dalga yüksekliği ve eğim değerlerinin durumu

Şekil 5.57’de genetik algoritma ile yapılan iterasyon sürecinde ulaşılan en uygun dizilere ait belirgin dalga yükseklikleri ve eğim değerleri dönüştürülmüş eksen takımları üzerinde verilmiştir. Burada, iterasyon sürecinde ulaşılan çözümlerin rassal bir nitelik taşıdığı ve global minimum noktaları oluşturan aralık boyunca yığıldığı gözlenmektedir. Şekil 5.58’de ise gradyen azalma algoritması ile yapılan sayısal optimizasyonun genetik algoritma ile yapılan optimizasyondan farklı bir yapıda gerçekleştiği görülmektedir. Optimum çözüme, hareket doğrultusundaki iterasyonlarla (Bölüm 3.1.1) ulaşmakta ve hareket doğrultusundaki ilerleme global optimum çözümü veren aralıkta sona ermektedir. Gradyen değerinin çok küçük değerler alması sonucunda, fonksiyon değerleri küçük salınımlarla sabit kalmaktadır. Şekil 5.59’da ise ikinci moment yöntemiyle ulaşılan çözüm noktasının, genetik algoritma ve gradyen azalma algoritması ile elde edilen çözümlere göre optimum çözümü sağlayamadığı görülmektedir.

Yıkım yüzeyinin ya da güvenilirlik indeksinin eksen uzayının başlangıç noktasından uzaklaşması veya yaklaşması, tasarım açısından, güvenli bölgeyi belirler. Bu nedenle de yıkım yüzeyinin konumu, sistemin güvenilirliğini etkilediğinden sözkonusu uzaklık güvenirliliğin belirlenmesinde ölçüt alınır. Yapısal güvenilirlik analizlerinde karşılaşılan en önemli sorunlardan biri yerel minimum noktalarının, güvenilirlik indeksinin belirlenmesinde belirleyici olmasıdır; bu da gerçek (en olası) yıkılma yüzeylerini temsil etmediğinden yapının beklenen seviyelerin de altında yıkılabilmesine neden olmaktadır.

Elde edilen sonuçlar karşılaştırıldığında, ikinci moment yöntemleri ve genetik algoritma ile elde edilen güvenilirlik indeksleri arasında önemli oranda fark bulunmuş olup genetik algoritmanın gerçek (yerel olmayan) optimum çözüme ulaştığı açıktır. İkinci moment yaklaşımlar, yerel minimum noktaları bulunan yıkım yüzeylerinde iteratif algoritmaları nedeniyle doğru sonuç vermeyebilir (Burchart, 1992). Ancak genetik algoritmalar, çoklu yerel minimum noktaları olan optimizasyon problemlerinde bile doğru sonuca (mutlak minimum veya maksimum) ulaşabilen bir yöntemdir (António, 2001). Monte Carlo Benzeşimi gözönüne alınan değişkenlerin olasılık dağılımlarına ve istatistik parametrelerine bağlı rassal bir örnekleme

yöntemidir ve karmaşık problemlerin çözümünde yaygın olarak kullanılan etkin tekniklerden (Jeong and Sheno, 2000) birini oluşturmaktadır. Ancak, Monte Carlo Benzeşimi rassal örneklem üzerine kurulduğu için belirlenen yıkılma olasılıkları da rassal değişkenlerdir ve bu nedenle yıkılma olasılıkları aralık tahminleri olarak verilirler. Mersin yat limanı için yapılan güvenilirlik analizinde, Monte Carlo Benzeşimi ile elde edilen yıkılma olasılığı, ikinci moment yöntemiyle iteratif olarak bulunan yıkılma olasılığından yaklaşık % 25 fazla, genetik algoritma ile bulunan olasılıktan ise yaklaşık % 9,0 azdır. Yıkılma olasılıkları dikkate alındığında, gradyen azalma ve tepe tırmanması yöntemleriyle genetik algoritma birbirine çok yakın sonuçlar vermiştir (Çizelge 5.22). Genetik algoritmanın, optimizasyon problemlerinde uygulanabilecek daha az karmaşık ve zaman alıcı bir yöntem olarak, yaklaşık çözümler veren ikinci moment yaklaşımından daha uygun olduğu ve taş dolgu dalgakıranların daha emniyetli tasarımını sağlayacağı bu çalışma ile Mersin yat limanı örneği için kanıtlanmıştır.

Genetik algoritma ile optimizasyonu rassal optimizasyondan ayıran en büyük farklılık genetik operatörlerin kullanılmasıdır. Genetik operatörler yardımıyla yüksek uygunluk değerine sahip yeni dizilerin oluşması arama uzayını daha uygun (daha yüksek uygunluk değerine sahip diziler) çözümlerin bulunması yönünde genişletir. Çaprazlama operatörü, diziler arasında bilgi (gen) alış-verişi yoluyla daha uygun bireylerin oluşumuna olanak sağlamakla birlikte özellikle dizilerin birbirine yakınsaması halinde bunu garanti etmemektedir; çaprazlama sonrası ortaya çıkan diziler de birbirine benzer olacaktır. Arama uzayının bu şekilde kısıtlandığı durumlarda mutasyon operatörü, çaprazlama yoluyla üretilemeyen uygunluk değeri yüksek dizilerin ortaya çıkmasına olanak sağlamaktadır.

Mersin yat limanı güvenilirlik analizi örneğinde yapılan genetik algoritma uygulamasının iterasyon süreci de bu çerçevede değerlendirilebilir: İlk 50 iterasyonda çok hızlı artan uygunluk değerleri dizilerin birbirine yakınsamasıyla çok yavaş değişmeye başlamış ancak mutasyona ve rassal aramaya bağlı olarak uygunluk değerinde gözlenen ani artışlarla (Şekil 5.53) birlikte güvenilirlik indeksi değerlerinde de ani azalmalar gözlenmiştir (Şekil 5.54); İterasyon sayısının 292. noktasından

itibaren uygunluk değerlerinde bir değişim ortaya çıkmamış ve bu noktada elde edilen güvenilirlik indeksi değeri olası global minimum değer olarak kabul edilmiştir. Her iterasyonda elde edilen en büyük uygunluk fonksiyonu değerleri, sözkonusu iterasyon için en uygun diziyi başka bir deyişle uygun çözümü vermektedir. Bütün iterasyon sürecinde ulaşılan en yüksek uygunluk fonksiyonu değeri de olası global optimum çözüme karşılık gelir. Bu nedenle Şekil 5.53’de verilen iterasyon sürecinde hesaplanan uygunluk fonksiyonu değerlerinin artışıyla en uygun çözüme ulaşılmaktadır. Bu durum, Şekil 5.54’de yine her iterasyonda en yüksek uygunluk değerlerine sahip diziler için hesaplanan güvenilirlik indeksi değerlerinin değişiminde de görülmektedir: İterasyon sırasında uygunluk fonksiyonu değerlerindeki artış, güvenilirlik indeksinin önceki iterasyonlara göre daha düşük değerler almasını sağlamaktadır.

İterasyon sayısının çok büyük değerlere ulaşmasıyla çaprazlama ve mutasyon operatörlerinin topluluk içindeki en uygun dizileri bozma (corrupt) olasılığına karşı (Manoharan and Shanmuganathan, 1999) iterasyon sayısı düşük tutulmuştur. İkinci moment yaklaşımının, performans fonksiyonunun doğrusallaştırılması nedeniyle yaklaşık çözümler vermesi yerel minimum noktaların varlığıyla birlikte (Çizelge 5.22) deterministik ve stokastik yöntemler arasındaki farkı da ortaya koymaktadır.

Taş dolgu dalgakıranlarda Mersin Yat Limanı örneği için değişik yöntemlerle yapılan ve Çizelge 5.22’de özetlenen sonuçlar mühendislik uygulamaları açısından değerlendirildiğinde, genetik algoritmanın diğer yöntemlere kıyasla daha kolay uygulanabilir olmasının önemli bir avantaj oluşturduğu söylenebilir. Çünkü, genetik algoritmalar uygunluk fonksiyonun kodlanabilmesi koşuluyla her türlü optimizasyon problemine kolaylıkla uygulanabilmektedir. Özellikle bu yöntemde çok karmaşık fonksiyonların optimizasyonunda türev bilgisine ihtiyaç duyulmaması ve genetik algoritmanın stokastik bir arama yöntemi olması, klasik optimizasyon yöntemlerine göre önemli üstünlükler olarak göze çarpmaktadır. İkinci moment yöntemi, uygulanması kolay olmakla birlikte fonksiyonun doğrusallaştırılması nedeniyle, yaklaşık çözümler vermektedir ve farklı yapılarıdaki güvenilirlik düzeylerinin karşılaştırılması gerektiğinde kullanılması daha uygun olacaktır.

Tepe tırmanması yöntemi, optimizasyon problemlerinde kullanılan başka bir iteratif yapay zeka tekniğidir. Ancak bu yöntem yersel bir arama algoritması olduğundan (local search algorithm), arama uzayındaki herhangi bir nokta için yersel optimum noktaların aranması ve bu yersel optimum noktaların tüm arama uzayı için genelleştirilmesine dayanmaktadır. Global optimum çözüme dolaylı olarak gidildiğinden genetik algoritmaya kıyasla hızlı çözümler vermemektedir. Monte Carlo Benzeşimi rassal örneklem üzerine kurulduğu için, elde edilen yıkılma olasılıkları da rassal değişkenlerdir ve aralık tahminleri olarak verilirler.

Yöntemlerin yukarıda sıralanan özellikleri dikkate alındığında, genetik algoritmanın çok amaçlı optimizasyon problemlerinde kullanılmasının mühendislik uygulamalarında hızlı ve doğru çözüme ulaşmayı kolaylaştırdığı görülmüştür.

Sonuç olarak, bu çalışmada, yapay zeka teknikleri olan yapay sinir ağları, bulanık sistem ve bulanık sinir ağları, stabilite sayılarının belirlenmesi; genetik algoritma ise güvenilirlik analizi olmak üzere taş dolgu dalgakıranlara değişik tasarım aşamalarında Türkiye'deki ilk uygulamalardan biri olmak üzere başarıyla uygulanmış ve mevcut yöntemlerle karşılaştırılmıştır. Yapay zeka teknikleri, yüksek kapasiteli (örneğin 64 MB RAM ve Pentium III işlemcili) bilgisayarlarda kullanılan programlara ve veri özelliklerine bağlı olarak 2-5 dakikalık CPU (merkezi işlem ünitesi) zamanı içinde sonuç üretebilmekte olup kıyı mühendislerinin mevcut yöntemlerle karşılaştırmalı olarak kullanımına uygun olduğu bu çalışma ile ortaya konmuştur. Dünya literatüründe de bu üç yapay zeka tekniğinin birlikte taş dolgu dalgakıranlara uygulandığı geniş kapsamlı çalışmalardan biridir.

Yüksek derecede belirsizlik içeren taş dolgu dalgakıranların tasarımında, deterministik yaklaşım yerine doğrusal olmayan yapay zeka tekniklerinin kullanılması karşılaşılan belirsizliklerin işlenebilmesi veya kaynaklarının belirlenerek istatistiki olarak azaltılması (Ang and Tang, 1975) yoluyla kıyı yapılarının daha ekonomik ve güvenli olarak tasarlanabilmesine katkıda bulunmakta ve karmaşık modellere gereksinim duyulmadan modelleyebilme olanağı sağlamaktadır.

6. SONUÇ VE ÖNERİLER

İnsan gibi davranabilen ve düşünebilen sistemlerin geliştirilmesine yönelik çalışmaların tümünü temsil eden yapay zeka, gelişimini sürdüren yeni bir disiplin olup kullanım amacına ve yerine göre değişik uygulama alanları ya da tekniklerden meydana gelmektedir. Yapay zeka teknikleri, karmaşık başka bir deyişle yüksek derecede belirsizlikler içeren sistemlerin modellenmesi amacıyla birçok mühendislik dalında yaygın olarak kullanılmasına karşın kıyı mühendisliği alanında henüz yeterli kullanım alanı bulamamıştır. Bu çalışmada, yapay zeka tekniklerinden olan yapay sinir ağları, bulanık mantık, bulanık sinir ağları ve genetik algoritmalar taş dolgu dalgakıranların ön tasarıma ve güvenilirlik analizine yönelik olarak değişik aşamalarda uygulanmıştır. Dalga parametrelerinin tahmininde yapay sinir ağları; stabilite katsayılarının belirlenmesinde yapay sinir ağları ile birlikte bulanık sistem ve bulanık sinir ağları kullanılmış olup güvenilirlik analizi genetik algoritmalar yardımıyla yapılmıştır. Bu çalışmadan elde edilen sonuçlar aşağıdaki şekilde özetlenebilir;

1) Alanya dalga istasyonunda işletme sırasında ortaya çıkan sorunlar nedeniyle ölçülemeyen eksik dalga parametreleri yapay sinir ağları ile tahmin edilmiştir. Eksik dalga verilerinin tamamlanmasında ileri ve geri beslemeli olmak üzere iki farklı ağ tipi kullanılmış; sözkonusu yapay sinir ağları tek değişkenli (dalga verileri) ve çok değişkenli (dalga verileri ve rüzgar hızı) olarak ve dalga verileri (belirgin dalga yüksekliği, periyodu ve yönü) aynı anda tahmin edilecek şekilde oluşturulmuştur. Yalnızca rüzgar verilerine bağlı olarak geliştirilen ve yüksek korelasyonlu tahminler vermeyen yapay sinir ağlarından (Deo et al., 2001) farklı olarak, yapay sinir ağları, rüzgar ve dalga verilerinin birlikte kullanıldığı çok değişkenli tahmin modelleri olarak tasarlanmış ve dalga parametrelerinin tahmini, meteorolojik verilerle de desteklenmiştir.

2) Yapay sinir ağlarının eğitilme aşamasında momentum katsayılı gradyen azalma ve konjuge gradyen eğitme algoritmaları etkin olarak kullanılmıştır. Doğrulama veri kümesi kullanılarak “erken durma” yönteminden yararlanılması, yapay sinir ağlarının modelleyebilme yeteneğini artırmıştır. Eğitilen yapay sinir ağlarının tümü, tek ve çok değişkenli doğrusal modellere göre tahminlerindeki yüksek determinasyon katsayılarından dolayı daha başarılıdır.

3) Yapay sinir ağları eğitme algoritmalarına göre karşılaştırıldığında, konjuge gradyen eğitme algoritması ile eğitilen ağların, momentum katsayılı gradyan azalma algoritması ile eğitilen ağlara göre daha yüksek determinasyon katsayılarına sahip oldukları ortaya konmuştur. Konjuge gradyen eğitme algoritması, iterasyon sayısındaki azalmaya bağlı olarak yapay sinir ağlarının genelleyebilme yeteneğini artıran bir faktör olmuştur.

4) Yapay sinir ağları ağ tiplerine göre karşılaştırıldığında ve modelleme yeteneklerinin ölçüsü olarak determinasyon katsayıları dikkate alındığında, geri beslemeli denetimli sinir ağı (Elman tip sinir ağı) eksik dalga verilerinin tamamlanmasında ileri beslemeli denetimli sinir ağlarına kıyasla daha başarılıdır. Yapılan kısa aralıklı tahminlerde, yapay sinir ağının tek veya çok değişkenli olması önemli bir fark göstermemektedir. Uzun aralıklı tahminlerde, ağların girdi verileri olarak dalga parametrelerinin yanında rüzgar hızlarının da kullanılması (çok değişkenli modeller) dalga verilerinin tahminine önemli katkıda bulunmaktadır.

5) Eğitme aşamasında kullanılan dalga ölçümü verilerinin uzunluğu (veri tabanındaki girdi ve çıktı vektörlerinin sayısı) ağların tahmin yeteneğini önemli ölçüde etkileyen bir faktördür: Ağların eğitilmesinde kullanılan dalga ölçümlerindeki artış, yapay sinir ağlarının tahmin yeteneğini artırmaktadır.

6) Yapay sinir ağıları veri tabanlı bir modelleme biçimi olduğundan, kıyı yapılarının tasarım aşamasında, deniz mühendisliği uygulamalarında ve dalga verilerinin tahmini aşamasında kullanılabilir. Karmaşık modellere gereksinim duyulmadan, doğrusal/deterministik modellerin karmaşık doğa olaylarını ve sınır koşullarını modellemede yetersiz kaldığı durumlarda etkin olarak kullanılabilir. Yapay sinir ağlarının güvenilirliği, veri tabanının (ölçümlerin) güvenilirliğine doğrudan bağlıdır.

7) Tasarlanan ve eğitilen ileri beslemeli denetimli sinir ağıları, dalgakıran stabilite sayısını ayrıntılı matematiksel modellere ihtiyaç duyulmaksızın, karmaşık sistemler olmalarına rağmen, başarıyla modelleyebilmiş; bulanık sistemler uzman bilgisini temsil eden bulanık kurallar ve sözel değişkenler yardımıyla kıyı yapılarının tasarımında karşılaşılan belirsizlikleri işleyebilmiştir. Yapay sinir ağıları ve bulanık sistemler, bulanık sinir ağıları şeklinde kombine edilerek daha gelişmiş bir yöntem şeklinde Mersin yat limanı ana dalgakıranına uygulanmıştır.

8) İleri beslemeli denetimli sinir ağlarının eğitilmesinde mevcut veri tabanının doğrudan kullanılması halinde, yapay sinir ağlarının tahmin yeteneği Van der Meer denklemlerine oranla düşük bulunmuştur. Ancak, eğitime aşamasında kullanılan veri tabanına rassal değişken ilave (noise) edilmesi korelasyon katsayıları dikkate alındığında, ağların tahmin yeteneğini önemli oranlarda artırmıştır. Rassal değişken ilave edilmesi ile, literatürde yer alan çalışmadan (Mase et. al., 1995) farklı olarak Van der Meer denklemleriyle aynı oranda yüksek korelasyon katsayılarına sahip tahminler elde edilmiştir.

9) İleri beslemeli denetimli sinir ağının eğitime ve test aşamasında kullanılan girdi vektörlerinin oluşturduğu veri tabanı için Esas Bileşen Analizi yürütülmüştür. Veri tabanının birinci ve ikinci mertebeden esas bileşenler üzerindeki dağılımı geniş bir aralıkta değişmektedir. Ağırlık faktörleri dikkate alındığında birinci mertebeden esas bileşen üzerinde dalga sayısının çok düşük bir etkisi vardır. İlk dört esas bileşen toplam değişimin (varyansın) % 100'e yakın kısmını açıklamaktadır.

10) Yapay sinir ağlarının eğitime aşamasında, girdi vektörlerinin ilk beş ve ilk dört esas bileşenden oluşması yapay sinir ağlarının tahmin yeteneğini belirgin ölçüde artırmaktadır.

11) Dalga sayısı gözönüne alınmadan permeabilite katsayısı, eğim, Iribarren sayısı ve hasar seviyesi değerleri ile eğitilen yapay sinir ağına ait test sonuçları (tahmin edilen stabilite sayıları) gözönüne alınan gerçek stabilite sayıları ile yüksek korelasyon göstermektedir.

12) Stabilite sayılarının belirlenmesi amacıyla oluşturulan bulanık sistemin girdileri belirgin dalga yüksekliği, periyodu ve hasar seviyesinden oluşmakta ve sistemin çıktılarına karşılık gelen stabilite sayısının tipik değerleri Van der Meer denklemlerine bağlı olarak belirlenmektedir. Ancak, bulanık sistemin çıktıları Van der Meer denklemlerine kıyasla düşük bir tahmin yeteneği göstermektedir. Kural tabanının oluşturulmasında başka bir yapay zeka yaklaşımı olan Adeli-Hung Algoritmasının (AHA), Van der Meer denklemleriyle birlikte kullanılması bulanık sistemin tahmin yeteneğini önemli oranda artırmaktadır. Adeli Hung Algoritması ile yapılan kümeleme işlemi, bulanık kural tabanının çıktılarını oluşturan stabilite sayılarına ait bulanık alt kümelerin kesin değer aralıklarının saptanmasına yardımcı olmuştur.

13) Bulanık sinir ağları, Van der Meer denklemlerine ve ileri beslemeli denetimli sinir ağlarına kıyasla düşük korelasyon katsayılı tahminler vermiştir. Bulanık sinir ağlarının eğitime aşamasında, veri kümelerine belirli oranlarda rassal değişkenler ilave edilmiş, ancak bu işlemler oluşturulan ağların mevcut tahmin yeteneklerinin geliştirilmesine önemli oranda katkıda bulunmamıştır.

14) Bulanık sinir ağlarının eğitilmesinde mevcut veri kümesindeki değişkenlik (varyans) üzerinde dalga sayısının daha düşük etkisini ortaya koyan Esas Bileşen Analizi (Bölüm 5) dikkate alındığında, başka bir deyişle ağ girdileri olarak permeabilite katsayısı, Iribarren sayısı, eğim ve hasar seviyesi tanımlandığında (ağ girdilerinde dalga sayısının kullanılmaması durumunda), bulanık sinir ağının,

korelasyon katsayılarına göre ölçülen tahmin yeteneğinde önemli bir değişiklik gözlenmemiştir.

15) Oluşturulan yapay zeka sistemlerinin davranışı, diğer tasarım parameterleri sabit iken belirgin dalga yüksekliğinin ve eğimin değişmesi halinde hasar seviyesine ve stabilite sayısına bağlı olarak Van der Meer denklemleri ile karşılaştırılmıştır: Yapay sinir ağı ile tahmin edilen stabilite sayıları düşük hasar seviyelerinde küçük farklar göstermesine karşın; bulanık sinir ağı ve bulanık sistem sonuçları düşük hasar seviyelerinde daha büyük farklar göstermiştir. Yapay zeka teknikleri ve Van der Meer denklemleri ile elde edilen stabilite sayıları arasındaki ilişki korelasyon katsayıları dikkate alındığında birbirine yakın eğilimler göstermiştir. Yapay sinir ağı, taş çapları açısından Van der Meer denklemlerine yakın sonuçlar vermiştir. Düşük ($S=2$) ve yüksek ($S=10$) hasar seviyeleri için hesaplanan taş ağırlıkları arasındaki fark, yapay sinir ağı kullanıldığında yaklaşık % 25, Van der Meer denklemi kullanıldığında yaklaşık % 27 olmuştur. Hasar seviyesinin seçimi, taş dolgu dalgakıranların maliyetini değişik biçimlerde etkilediği için önemlidir. Hasar seviyesinin düşük seviyelerde seçilmesi yapının ilk maliyetini artırırken; yüksek hasar seviyeleri yapının bakım ve onarım maliyetlerinde artışa neden olmaktadır. Bu nedenle, ön tasarım aşamasında maliyet ve risk optimizasyonu ile taş çaplarının belirlenmesi yapının ekonomik ve emniyetli olarak tasarlanmasını sağlayacaktır.

16) Mersin yat limanı ana dalgakıranının optimum yıkılma noktasının bulunmasında ikinci moment yönteminin doğrudan ve iteratif olarak kullanılmasının yanında genetik algorithmadan yararlanılmıştır. Elde edilen sonuçlar karşılaştırıldığında genetik algoritma ve ikinci moment yöntemleriyle bulunan yıkılma olasılıkları arasında önemli oranda fark vardır. Genetik algoritma global optimum çözümü sağlamada daha başarılıdır. Kurulan amaç fonksiyonun optimizasyonu, gradyen azalma ve tepe tırmanması yöntemleriyle de karşılaştırılmıştır. Yıkılma olasılıkları dikkate alındığında bu yöntemlerle genetik algoritma birbirine yakın sonuçlar vermektedir. Yapının yıkılma olasılığı, ayrıca rassal bir örnekleme yöntemi olan Monte Carlo Benzeşimi ile belirlenmiştir. Bu yöntemle bulunan yıkılma olasılığı ile genetik algoritma ile bulunan yıkılma olasılıkları arasındaki fark ikinci moment

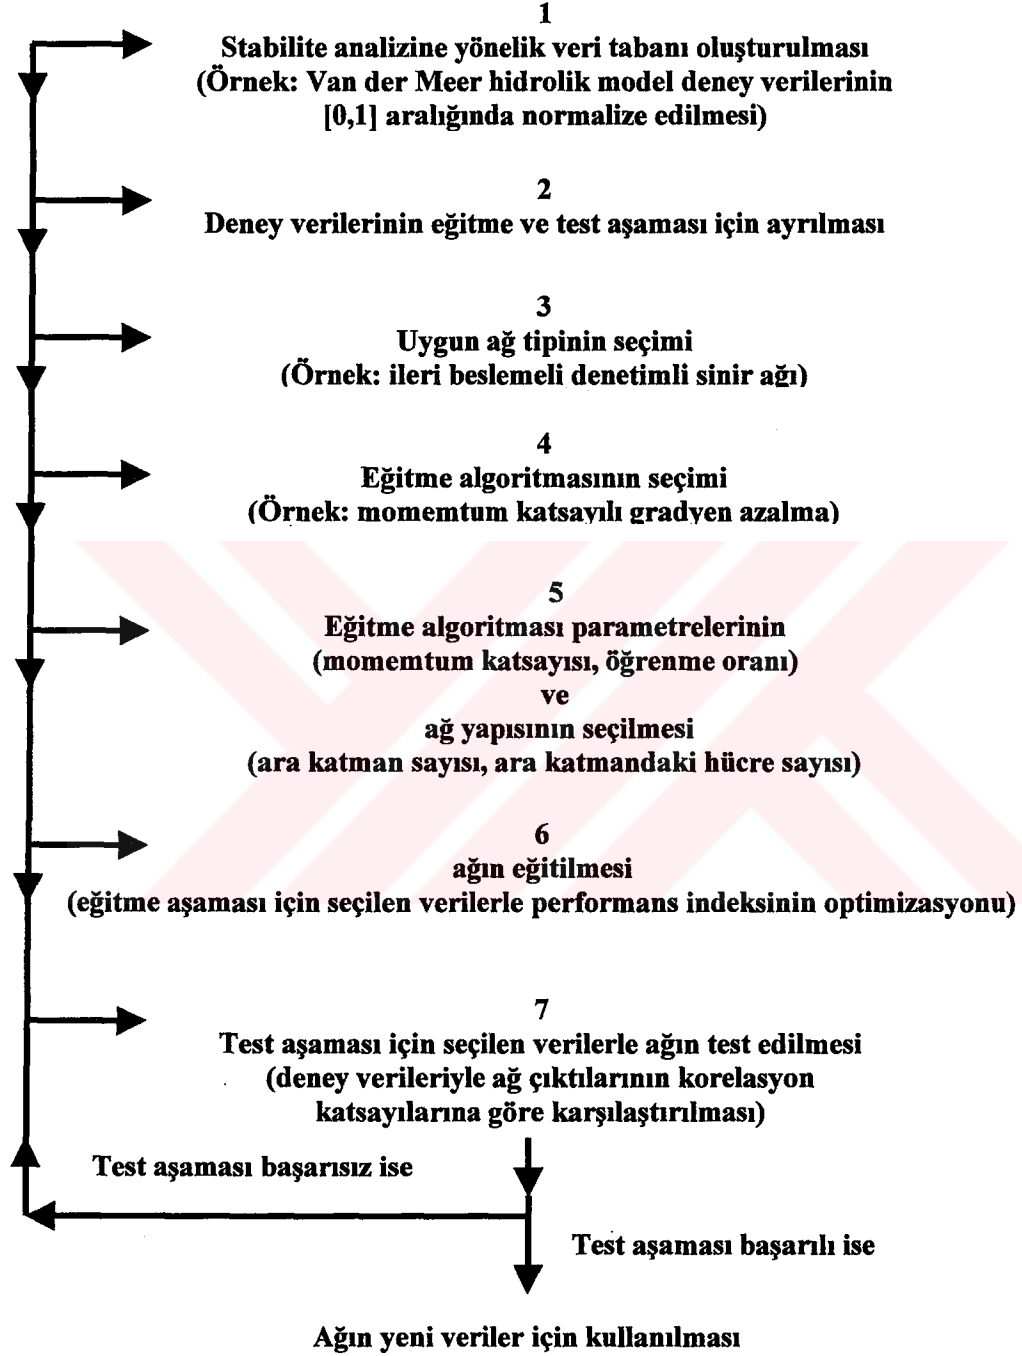
yöntemine kıyasla daha düşüktür ve yıkılma olasılıkları dikkate alındığında, gradyen azalma ve tepe tırmanması yöntemleriyle genetik algoritma birbirine çok yakın sonuçlar vermiştir. Bu nedenle güvenilirliğe dayalı tasarımda, amaç fonksiyonunun optimizasyonunda, genetik algoritma etkin bir yöntem olarak kullanılabilir.

17) Genetik algoritma ile optimizasyonu rassal optimizasyondan ayıran en büyük farklılık genetik operatörlerin kullanılmasıdır. Genetik operatörler yardımıyla yüksek uygunluk değerine sahip yeni dizilerin oluşması arama uzayını daha uygun çözümlerin (daha yüksek uygunluk değerine sahip dizilerin) bulunması yönünde genişletir. Mersin yat limanı güvenilirlik analizi uygulamasındaki iterasyon sürecinde; başlangıç topluluğunun oluşturulmasında tasarım değişkenlerine ait olasılık dağılımlarının kullanılması mevcut çözümlerin kısa iterasyon sürecinde birbirine yakınsanmasına neden olmuş, fakat mutasyon operatörünün devreye girmesiyle uygunluk değerlerinde de ani artışlar gözlenmiştir. Çözüm uzayı daha uygun çözümlerin bulunması yönünde genişlemiş ve global optimum çözüme ulaşılabilmiştir. Mersin yat limanı örneği için yapılan bu çalışmada, genetik algoritma, yalnızca uygunluk fonksiyonu değerleri kullanıldığından daha az karmaşık ve daha az zaman alıcı bir yöntem olarak optimizasyon problemlerine uygulanmış ve yaklaşık çözümler veren ikinci moment yönteminden daha doğru sonuçlar vermiştir.

18) Yapay sinir ağları, bulanık sistem, bulanık sinir ağları ve genetik algoritma taş dolgu dalgakıranlara değişik tasarım aşamalarında uygulanmıştır. Yapay zeka teknikleri, çözümü garanti etmemek veya eğitilebilen sistemler için eğitme aşamasının uzun zaman alması gibi risk faktörleri taşımalarına rağmen, yüksek kapasiteli bilgisayarlarla mevcut yöntemlere kıyasla daha kolay/ekonomik çözümler (Ko and Cheng, 2002) üretmektedir. Yüksek derecede belirsizlik içeren taş dolgu dalgakıranların tasarımında karmaşık modellere gerek duyulmadan, doğrusal olmayan yapay zeka tekniklerinin kullanılması belirsizliklerin azaltılması veya işlenebilmesi yoluyla daha ekonomik ve güvenli tasarım sağlamaktadır.

19) Yapay zeka teknikleri, gözönüne alınan problemin niteliğine bağlı olarak seçilir ve belirli aşamalarla uygulanır. Örneğin, yapay sinir ağlarının taşdolgu

dalgakıranların stabilite analizine yönelik olarak uygulanması aşağıda verilen akış şeması içinde gerçekleştirilmiştir:



Sonuç olarak bu tez çalışmasında, taş dolgu kıyı yapılarının ön tasarımı için Van der Meer deney verilerini içeren bir “tasarım yapay sinir ağı” geliştirilerek, bu ağın mühendislik uygulamalarındaki kullanılabilirliği gerçekleştirilmiştir. Ayrıca, güvenilirliğe dayalı tasarımda, ikinci moment yöntemi yerine genetik algoritmanın kullanılmasının daha güvenilir sonuçlar vereceği ortaya konmuştur.

Öneriler:

- 1) Yapay zeka tekniklerinin kıyı mühendisliği alanında yaygın olarak kullanımı ve bu çerçevede elde edilecek deneyimler, bu tekniklerin kıyı mühendisliği problemlerinin çözümünde sağlayacağı yararların daha açık bir şekilde değerlendirilebilmesini sağlayacaktır. Yapay zeka tekniklerinin kıyı mühendisliği alanında geniş bir kullanım potansiyeli olmasına karşın bu tekniklerin hangi seviyelerde ve nasıl kullanılacağını karşılaşılan problemin niteliği belirleyecektir.
- 2) Yüksek modelleme yeteneklerine sahip yapay veya bulanık sinir ağlarının probleme bağlı olarak yeterli ve güvenilir veri tabanının olması halinde değişik problemlere uygulanma ve değişik biçimlerde entegre edilme olanakları vardır. Örneğin, yapay sinir ağlarının sağlıklı rüzgar verileri ile eğitilmesi veya değişik tipte yapay sinir ağlarının kullanılması dalga verilerinin tahmini açısından etkin bir uygulamadır.
- 3) Ölçüm işinin pahalı ve zor bir iş olması dikkate alındığında bulanık mantık önemli alternatif modelleme tekniklerinden biri olmaktadır. Bulanık mantığın taş dolgu dalgakıranların tasarımına yönelik olarak yapılacak uygulamalarında farklı yaklaşımlarla birlikte doğrudan uzman bilgiyi baz alan (uzman) bulanık sistemlerin oluşturulması yararlı olacaktır.
- 4) Genetik algoritmaların bir çok optimizasyon probleminin çözümünde kullanıma olanağı bulunmaktadır, örneğin özellikle dalgakıranların risk analizi ile birlikte maliyet analizini de içeren çok amaçlı optimizasyon problemlerinde etkin olarak kullanılabilir.

5) Yüksek derecede belirsizlik içeren taş dolgu dalgakıranların, deterministik yöntemler yerine doğrusal olmayan yapay zeka teknikleriyle tasarlanması, karşılaşılan belirsizliklerin azaltılması ya da işlenebilmesi yoluyla bu yapıların karmaşık modellere gereksinim duyulmadan modellenenebilmesine olanak sağlamıştır. Yapay sinir ağları ile bulanık sinir ağları, genel olarak birbirine yakın eğilimler göstermesine karşın benzer davranışlar bulanık sistemde gözlenmemiştir. Bu durum, eğitilebilen sistemlerin modelleyebilme yeteneği açısından statik bir yapıya sahip olan bulanık sistemlerden genellikle daha başarılı olduğu düşüncesini desteklemektedir. Özellikle yapay sinir ağı, deterministik tasarımla (Van der Meer denklemleri) aynı düzeyde tahmin yeteneği göstermiş olup bu çerçevede yapılacak çalışmalarda, ağlarının eğitime ve test aşamalarında değişik model deneylerinden elde edilecek verilerin kullanılması sonuçların geliştirilmesinde yararlı olacaktır. Bulanık sinir ağlarının oluşturulmasında, bulanık alt kümelerin saptanması önemli zorluklardan birini oluşturmaktadır. Bu nedenle, sözel değişkenlere ait en uygun bulanık alt kümelerin saptanmasında, bulanık sinir ağlarına alternatif olarak bulanık sistemlerle yapay sinir ağlarının entegre edildiği nöro-bulanık (neuro-fuzzy systems) sistemlerin denenmesi yararlı olacaktır. Eğitilebilen bir sistem için gerekli veri tabanının olmaması halinde, belirsizliklerin işlenebilmesi açısından, karmaşık sistemlerin modellenenebilmesine bulanık sistemlerin önemli yararlar sağlayacağı dikkate alınmalıdır. Bulanık kural tabanlarının oluşturulmasında daha ayrıntılı ve geniş bir bilgi tabanından yararlanılarak daha yetkin bulanık sistemlerin kurulması gerekmektedir.

KAYNAKLAR

- Al-Saba, T., El-Amin, I., 1999, Artificial Neural Networks as Applied to Long Term Demand Forecasting, **Artificial Intelligence in Engineering**, 13, 189-197.
- Ang, A. H. S., Tang, W. H., 1975, Probability Concepts in Engineering Planning and Design, **John Wiley and Sons**, Vol. II., USA.
- António, C.A.C., 2001, A Hierarchical Genetic Algorithm for Reliability Based Design of Geometrically Non-Linear Composite Structures, **Composite Structures**, 54, 37-47.
- Balas, C. E., Ergin, A., 2002, Reliability-Based Risk Assessment in Coastal Projects: Case Study in Turkey, **Journal of Waterway, Port, Coastal and Ocean Engineering**, ASCE, 128, 52-61.
- Balas, C. E., Koç, L., 2002, Risk Assessment of Vertical Breakwaters – A Case Study in Turkey, **China Ocean Engineering**, 16(1), 123-134.
- Balas., C.E., Balas, L., 2002, Risk Assessment of Some Revetments in Southwest Wales, United Kingdom, **Journal of Waterway, Port, Coastal and Ocean Engineering**, 128(5).
- Balas C.E., Ergin A., 2000, Sensitivity Study for the Second Order Reliability-Based Design Model of Rubble Mound Breakwaters, **Coastal Engineering Journal**, 42 (1), 57-86.
- Balas, C.E., 1998, A Risk Management Model for Coastal Projects, Unpublished Ph.D. Thesis, **The Graduate School of Natural and Applied Sciences, Middle East Technical University**, Ankara, Turkey.
- Balas C.E., Ergin A., A., 1997, Reliability-Based Risk Assessment Model for Coastal Projects, **Proceedings of the Third International Conference on the Mediterranean Coastal Environment (MEDCOAST'97)**, 2, 943-955, 11-14 November, Qawra, Malta.
- Balas C.E., Ergin A., Yüçemen S.M., 1995, Comparison of the Reliability-Based and Deterministic Design Procedures for Rubble Mound Breakwaters, **Proceedings of the Second International Conference on the Mediterranean Coastal Environment (MEDCOAST 95)**, 3, 1767-1782, 24-27 November, Tarragona, Spain.
- Balkin, S. D., Ord, J. K., 2000, Automatic Neural Network Modeling for Univariate Time Series, **International Journal of Forecasting**, 16, 509-515.

- Basherr, I.A., Hajmeer, M., 2000, Artificial Neural Networks: Fundamentals, Computing, Design, and Application., **Journal of Microbiological Methods**, 43, 3-31.
- Bayazıt, M., 1996, İnşaat Mühendisliğinde Olasılık Yöntemleri, **İTÜ İnşaat Fakültesi Matbaası**, 244, İstanbul.
- Belarbi, K., Bettou, K., Mezaache, A., 2000, Fuzzy Neural Networks for Estimation and Fuzzy Controller Design: Simulation Study for a Pulp Batch Digester, **Journal of Process Control**., 10,35-41.
- Box, G. E. P., Jenkins, G. M., 1976, Time Series Analysis Forecasting and Control, **Holden Day Inc.**, California, USA.
- Burcharth, H. F., 1992, Reliability Evaluation of a Structure at Sea, **Proc., Short Course on Design and Reliability of a Coastal Structures: Structural Integrity**, A. Lamberti, ed., Tecnoprint Snc, Venice, Italy, 511-545.
- Buckley, J. J., Hayashi, Y., 1995, Neural Nets for Fuzzy Systems, **Fuzzy Sets and Systems**, 71, 265-276.
- Caldas, G. L., Norford, L. K., 2002, A Design Optimization Tool Based on Genetic Algorithm, **Automation in Construction**, 11, 173-184.
- CCP., 1993, Neural Networks and Combinatorial Optimization in Structural Engineering, **Civil-Comp Limited**, s 165, Meigle Printers Ltd., Scotland.
- Choi, D. J., Park, H., 2001, A Hybrid Artificial Neural Network as a Software Sensor for Optimal Control of a Wastewater Treatment Process, **Water Research**, 35(16), 3959-3967.
- Coulibaly, P., Anctil, F., Bobee, B., 2000, Daily Reservoir Inflow Forecasting Using Artificial Neural Networks with Stopped Training Approach, **Journal of Hydrology**, 230, 244-257.
- Dash, P. K., Liew, A. C., Rahman, S., 1995, Peak Load Forecasting Using A Fuzzy Neural Network, **Electric Power System Research**, 32-19-23.
- De Gerssem H., Hameyer, K., 2001, Convergence Improvement of the Conjugate Gradient Iterative Method for Finite Element Simulations, **The International Journal for Computation and Mathematics in EEE**, 20 (1), 90-97.
- Deo, M. C., Gondane, D. S., Kumar, V. S., 2002, Analysis of Wave Directional Spreading Using Neural Networks, **Journal of Waterway, Port, Coastal and Ocean Engineering**, ASCE, 128 (1), 30-37.
- Deo, M.C., A. Jha, A., Chaphekar, K., Ravikant, K., 2001, Neural Networks for Wave Forecasting, **Ocean Engineering**, 28, 889-898.

- Deo, M.C., Kumar, N.K., 2000, Interpolation of Wave Heights, **Ocean Engineering**, 27, 907-919.
- Deo, M.C., Naidu, C. S., 1999, Real Time Wave Forecasting Using Neural Networks, **Ocean Engineering**, 26, 192-203.
- Doffner, G., 1996, Neural Networks for Time Series Processing, **Neural Network World**, 6(4), 447-468.
- Dunteman, G. H., 1989, Principal Component Analysis, Sage Publications, Sage University Paper (69), s 96, Newbury Park.
- Elman, J. L., 1990, Finding Structure in Time, **Cognitive Science**, 14, 179-211.
- Ergin A., Balas C.E., 1998, Implementation of a Reliability-Based Design Model in Turkey, **Proceedings of the 17th International Conference on Offshore Mechanics and Arctic Engineering, Proceedings on CD-ROM - Paper No: 98-1351**, 5-9 July 1998, Lisbon, Portugal.
- Ergin A., Balas C.E., 1997, Failure Mode Response Functions in Reliability-Based Design of Rubble Mound Breakwaters, **Proceedings of the Seventh International Offshore and Polar Engineering Conference, ISOPE'97,3**, 861-868, 25-30 May, Honolulu, U.S.A.
- Ergin, A., Özhan, E., 1986, Wave Hindcasting Studies and Determination of Design Wave Parameters for 15 Sea Regions, T. Report No: 35, **Coastal Engineering Research Center, Civil Eng. Department, Middle East Technical University**, Ankara, Turkey.
- Feuring, T., Lippe, W. M., 1999, The Fuzzy Neural Network Approximation Lemma, **Fuzzy Sets and Systems**, 102, 227-236.
- Goldberg, D. E., 1989, Genetic Algorithms In Search, Optimization and Machine Learning, **Addison-Wesley Publishing Company Inc.**, s 411, USA
- Golden, R. M., 1996, Mathematical Methods for Neural Network Analysis and Design, **Massachusetts Institute of Technology Press.**, s 419, USA.
- Gonzalez, A., Perez, R., 2001, An Experimental Study About the Search Mechanism in the SLAVE learning Algorithm: Hill Climbing Methods Versus Genetic Algorithms, **Information Sciences**, 136,159-174.
- Gupta, M. M., Qi, J., 1991, Theory of T-Norms and Fuzzy Inference Methods, **Fuzzy Sets and Systems**, 40, 431-450.

- Hancheng, Q., Bocai, X., Shangzheng, L., Fagen, W., 2002, Fuzzy Neural Network Modeling of Material Properties, **Journal of Materials Processing Technology**, 5647, 1-5.
- Hamilton, J. D., 1994, Times Series Analysis, **Princeton University Press**, s 799, Princeton, New Jersey.
- Harvey, R. L., 1994, Neural Network Principles, **Prentice-Hall Inc.**, s 197, New Jersey.
- Hsu, S. A., 1985, On the Correction of Land Based Wind Measurements for Oceanographic Application, **Proceedings of the 22th. International Conference on Coastal Engineering**, Sydney.
- Hudson, R. Y., 1953, Wave Forces on Breakwaters, **Transactions of the American Society of Civil Engineers**, ASCE, 11B, USA.
- Ishibuchi, H., Kwon, K., Tanaka, H., 1995, A learning Algorithm of Fuzzy Neural Networks with Triangular Fuzzy Weights, **Fuzzy Sets and Systems**, 71, 277-293.
- Jenkins, W. M., 1997, On the Application of Natural Algorithms to Structural Design Optimization, **Engineering Structures**, 19(4), 302-308.
- Jenkins, W. M., 1993, An Enhanced Genetic Algorithm for Structural Design Optimization, **Neural Networks and Combinatorial Optimization in Structural Engineering**, Civil-Comp Limited, s 165, Meigle Printers Ltd., Scotland.
- Jeong, H. K., Sheno, R. A., 2000, Probabilistic Strength Analysis of Rectangular FRP Plates Using Monte Carlo Simulation, **Computers and Structures**, 76, 219-235.
- Kalagirou, S. A., 1999, Applications of Neural Networks in Energy Systems, **Energy Conversion and Management**, 40, 1073-1087.
- Kamarthi S.V., Pittner, S., 1999, Accelerating Neural Network Training Using Weight Extrapolations, **Neural Networks**, 12 (9), 1285-1299.
- Kaya, M., 2001, Betonarme Yüksek Kiriş Tasarımında Genetik Algoritmaların Kullanılması, Yüksek Lisans Tezi, **Gazi Üniversitesi Fen Bilimleri Enstitüsü**, s128, Ankara.
- Kirkegaard, P.H., ve Rytter, A., 1993, The Use of Neural Networks For A Damage Detection and Location in a Steel Member, **Neural Networks and Combinatorial Optimization in Civil and Structural Engineering**, 1-9, Migle Press, UK.

- Ko, H. C., Cheng, M. Y., 2002, Hybrid use of AI Techniques in Developing Construction Management Tools, *Automation in Construction*, 519, 1-11.
- Kosko, B., 1997, *Fuzzy Engineering*, **Prentice Hall Inc.**, s 547, USA.
- Kröse, B., Van der Smagt, P., 1996, *An Introduction to Neural Networks*, **The University of Amsterdam**, s 135 Amsterdam.
- Kuo, R. J., Xue, K. C., 1999, Fuzzy Neural Networks with Application to Sales Forecasting, *Fuzzy Sets and Systems*, 108, 123-143.
- Kwan, H. K., Cai, Y., 1994, A Fuzzy Neural Network and its Application to Pattern Recognition, *IEEE Transactions on Fuzzy Systems*, 2(3), 185-193.
- Liang, R. H., Cheng, C. C., 2002, Short Term Load Forecasting by a Neuro-Fuzzy Based Approach, *Electrical Power and Energy Systems*, 24, 103-111.
- Manoharan, S., Shanmuganathan, S., 1999, A Comparison of Search Mechanism for Structural Optimization, *Computers and Structures*, 73, 363-372.
- Mase., H., Kitano., T., 1999, Prediction Model for Occurrence of Impact Wave Force, *Ocean Engineering*, 26, 949-961
- Mase, H., Sakamoto, M., Sakai, T., 1995, Neural Network for Stability Analysis of Rubble Mound Breakwaters, *Journal of Waterway, Port, Coastal and Ocean Engineering*, 121 (6), 294-299.
- Melchers, R. E., 1999, *Structural Reliability Analysis and Prediction*, **John Wiley and Sons Inc.**, 456, New York.
- Mohan, S., 1997, Parameter Estimation of Nonlinear Muskingum Models Using Genetic Algorithm, *Journal of Hydraulic Engineering*, 123(2), 137-142.
- Moshgbar, M., Parkin, R., Bearman, R. A., 1995, Application of Fuzzy Logic and Neural Network Technologies in Cone Crusher Control, *Minerals Engineering*, 8 (1), 41-50.
- Oliveria, K. A., Vannucci, A., Da Silva, E. C., 2000, Using Artificial Neural Networks to Forecast Chaotic Time Series, *Physica A*, 284, 394-404.
- Olofsson, T., Anderson, S., Östin, R., 1998, A Method for Predicting the Annual Building Heating Demand Based on Limited Performance Data, *Energy and Buildings*, 18, 101-108.
- Östernak, R., 1999, A Fuzzy Neural Network Algorithm for Multigroup Classification, *Fuzzy Sets and Systems*, s 105, 113-122.

- Özhan, E., Abdalla, S., 2000, Türkiye Kıyıları Rüzgar ve Derin Deniz Atlası, **Orta Doğu Teknik Üniversitesi, Kıyı ve Liman Mühendisliği Araştırma Merkezi**, s 445, Ankara.
- Özhan E., Ergin A., Yalçın A.C., 1994, Mersin Yacht Harbor Research Studies, Technical Report No: 51, **Coastal and Harbor Engineering Research Center, Civil Engineering Department, Middle East Technical University**, Ankara, Turkey.
- Palacharla, P. V., Nelson, P. C., 1999, Application of Fuzzy Logic and Neural Networks for Travel Time Estimation, **International Transactions in Operational Research**, 6, 145-160.
- Patterson, D. W., 1996., Artificial Neural Networks Theory and Applications, **Prentice Hall International Editions**, s 477, Korea.
- Pham, D. T., Pham, P. T. N., 1999, Artificial Intelligence in Engineering, **International Journal of Machine Tools and Manufacture**, 39, 937-949.
- Polgar, O., Fried, M., Lohner, T., Barsony, I., 2000, Comparision of Algorithms Used for Evaluation of Ellipsometric Measurements Random Search, Genetic Algorithms, Simulated Annealing and Hill Climbing Graph Searches, **Surface Science**, 457, 157-177.
- Principe, J. C., Euliano, N. R., Lefebvre, W. C., 2000, Neural and Adaptive Systems: Fundamentals through Simulations., **John Wiley and Sons Inc.**, s 656, New York, USA.
- Rajasekaran, S., Febin, M. F., Ramasamy, J. V., 1996, Artificial Fuzzy Neural Networks in Civil Engineering, **Computers and Structures**, 61(2), 291-302.
- Rao, S. S., 1996, Engineering Optimization Theory and Application, **John Wiley and Sons Inc.**, s 903, USA.
- Rojas, R., 1996, Neural Networks A Systematic Introduction, **Springer-Verlag Berlin Heidelberg**, s 502, Germany.
- Ross, T. J., 1995, Fuzzy Logic with Engineering Applications, **McGraw Hill Book Publishing Company**, s 600, USA
- Russel, S., Norwig, P., 1995, Artificial Intelligence: A Modern Approach, **Prentice Hall International Editions**, s 932, Singapore.
- Schalkoff, R. J., 1990, Artificial Intelligence: An Engineering Approach, **McGraw Hill Book Publishing Company**, s 646, Singapore.

- Schittenkopf, C., Deco, G., Brauer, W., 1997, Two Strategies to Avoid Overfitting in Feedforward Networks, **Neural Networks**, 10 (3), 505-516.
- Schilling, R. J., Harris, S. L., 2000, Applied Numerical Methods for Engineers, Brooks/Cole Publishing Company, s 715, USA.
- Simon, H. A., 1995, Artificial Intelligence: An Empirical Science, **Artificial Intelligence**, 77, 95-127.
- Skapura, D. M., 1996, Building Neural Networks, Addison-Wesley Publishing Company, s 286, New York.
- SPM, 1984, Shore Protection Manual, Vol:1, US army Corps of Engineers, s 99, Washington, USA.
- Svozil, D., Kvasnicka, V., Pospichal, J., 1997, Introduction to Multilayer Feed Forward Neural Net, **Chemometrics and Intelligent Laboratory Systems**, 39, 43-62.
- Tsai C.P., Lee, T.L., 1999, Back-propagation Neural Network in Tidal-Level Forecasting, **Journal of Waterway, Port, Coastal and Ocean Engineering**, 125 (4), 195-202.
- Tsai, C.P., Shen, J.N., Kerh, T., 1999, Wave Forecasting Using Neural Network Model, **Artificial Intelligence Applications in Civil and Structural Engineering**, Editor: Kumar and Topping, Civil-Comp. Press, 123-130.
- Tsang, E., Voudouris, C., 1997, Fast Local Search and Guided Local Search and Their Application to British Telecom's Work Force Scheduling Problem, **Operations Research Letters**, 20, 119-127.
- Tsoukalas, L. H., Uhrig, R. E., 1997, Fuzzy and Neural Approaches in Engineering, **John Wiley and Sons Inc.**, s 587, USA
- Van der Meer, J. W., 1988, Rock Slopes and Gravel Beaches Under Wave Attack, **Delft Hydraulics Publication**, No. 396, Delft, The Netherlands.
- Vlachos, D., Avaritsiotis, J., 1996, Fuzzy Neural Networks for Gas Sensing, **Sensors and Actuators B**, 33, 77-82.
- Walczak, S., Cerpa, N., 1999, Heuristic Principles for the Design of Artificial Neural Networks, **Information and Software Technology**, 41, 107-117.
- Wang, S., Le Mehaute, B., 1983, Duration of Measurements and Long Term Wave Statistics, **Journal of Waterway, Port, Coastal and Ocean Engineering**, ASCE, 109 (2), 236-247.

- Williams A.T., Davies P., Ergin A., Balas C.E., 1998, Coastal Recession and the Reliability of Planned Responses: Colhuw Beach, The Glamorgan Heritage Coast, Wales, UK, **Journal of Coastal Research, Coastal Education and Research Foundation (CERF)**, U.S.A, SI26, 72-79.
- WMO, 1988, Guide to Wave Analysis and Forecasting, **World Meteorological Organization**, No:702, s 172, Geneva, Switzerland
- Yang, Y., Xu, X., Zhang, W., 2000, Design Neural Networks Based Fuzzy Logic, **Fuzzy Sets and Systems**, 114, 325-328.
- Yeh, I. C., 1999, Modeling Chaotic Two-Dimensional Mapping with Fuzzy-Neuron Networks, **Fuzzy Sets and Systems**, 105, 421-427.
- Zadeh, L. A., 1999, Fuzzy Logic and the Calculi of Fuzzy Rules, Fuzzy Graphs, and Fuzzy Probabilities, **Computer and Mathematics with Applications**, 37, 35.
- Zadeh, L. A., 1997, Toward a Theory of Fuzzy Information Granulation and its Centrality in Human Reasoning and Fuzzy Logic, **Fuzzy Sets and systems**, 90, 111-127.
- Zhang, G. P., Patuwo, B. E., Hu, M. Y., 2001, A Simulation Study of Artificial Neural Networks for Nonlinear Time-Series Forecasting, **Computers and Operations Research**, 28, 381-396.

EKLER

EK 1

ESAS BİLEŞEN ANALİZİ

(PRINCIPAL COMPONENT ANALYSIS)

Esas bileşenler (y_j) gerçek değişkenlerin (x_j) doğrusal bir kombinasyonu olarak yeni bir koordinat düzleminde tanımlanmasından meydana gelir ve w : ağırlık faktörü, n : gerçek değişken sayısı ve p : örnek sayısı olmak üzere aşağıdaki şekilde ifade edilebilir ($j=1,2,...,n$):

$$y_l = w X \quad (1)$$

$$X = \begin{bmatrix} x_{11} & x_{12} \dots x_{1n} \\ x_{21} & x_{22} \dots x_{2n} \\ \vdots & \vdots \quad \vdots \\ \vdots & \vdots \quad \vdots \\ x_{p1} & x_{p2} \quad x_{pn} \end{bmatrix} \quad (2)$$

Birinci mertebeden esas bileşen (y_1) maksimum varyans doğrultusunda alınır ve $w_1^T w_1 = \sum_i w_{i1}^2 = 1$ kısıtlılık koşulunda aşağıda tanımlanan karesel fonksiyonun maksimizasyonu ile elde edilir:

$$y_1^T y_1 = w_1^T X^T X w_1 \quad (3)$$

(1) nolu eşitlik kısıtlılık koşulu ile birlikte Lagrange yöntemi kullanılarak ve L bileşik fonksiyonu olarak λ : Lagrangian çarpım olmak üzere aşağıdaki şekilde yeniden yazılabilir:

$$L = \mathbf{w}_1^T \mathbf{X}^T \mathbf{X} \mathbf{w}_1 - \lambda_1 (\mathbf{w}_1^T \mathbf{w}_1 - 1) \quad (4)$$

(4) nolu eşitliğin ağırlık faktörüne göre türevinin sıfıra eşitlenmesi sonucunda elde edilen (6) nolu eşitlik yardımıyla (3) nolu eşitlik (7) nolu eşitliğe dönüştürülür:

$$\frac{\partial L}{\partial \mathbf{w}_1} = 2 \mathbf{X}^T \mathbf{X} \mathbf{w}_1 - 2\lambda_1 \mathbf{w}_1 = 0 \quad (5)$$

$$\mathbf{X}^T \mathbf{X} \mathbf{w}_1 = \lambda_1 \mathbf{w}_1 \quad (6)$$

$$\mathbf{y}_1^T \mathbf{y}_1 = \mathbf{w}_1^T \lambda_1 \mathbf{w}_1 \quad (7)$$

(7) nolu eşitliğin çözümü ile birinci mertebeden esas bileşen (y_1) bulunur. İkinci mertebeden esas bileşen (y_2) yukarıda belirtilen yaklaşım içerisinde fakat y_1 ve y_2 birbirine dik (orthogonal) olacak şekilde ($\mathbf{w}_2^T \mathbf{w}_2 = 1$ ve $\mathbf{w}_1^T \mathbf{w}_2 = 0$) bulunur.

Burada λ parametresi $\mathbf{X}^T \mathbf{X}$ için özdeğerdir.

EK 2

BULANIK KURAL TABANI

Bulanık kural tabanına karşılık gelen tüm kurallar için seçilen permeabilite katsayısı (P), eğim ($\cot \theta$) ve dalga sayısı (N) değerlerinin sabit olduğu kabul edilmiş olup örneğin P, $\cot \theta$ ve N değerleri sırasıyla 0,1; 2 ve 3000 seçilen bir bulanık kural tabanını oluşturan bulanık kurallar dizisi aşağıdaki şekilde tanımlanmıştır:

R₁: EĞER H_s D VE T D VE S D İSE N_s D DİR VEYA

R₂: EĞER H_s D VE T O VE S D İSE N_s ÇD DİR VEYA

R₃: EĞER H_s D VE T Y VE S D İSE N_s ÇD DİR VEYA

R₄: EĞER H_s D VE T ÇY VE S D İSE N_s ÇD DİR VEYA

R₅: EĞER H_s O VE T D VE S D İSE N_s D DİR VEYA

R₆: EĞER H_s O VE T O VE S D İSE N_s ÇD DİR VEYA

R₇: EĞER H_s O VE T Y VE S D İSE N_s ÇD DİR VEYA

R₈: EĞER H_s O VE T ÇY VE S D İSE N_s ÇD DİR VEYA

R₉: EĞER H_s Y VE T D VE S D İSE N_s D DİR VEYA

R₁₀: EĞER H_s Y VE T O VE S D İSE N_s D DİR VEYA

R₁₁: EĞER H_s Y VE T Y VE S D İSE N_s ÇD DİR VEYA

R₁₂: EĞER H_s Y VE T ÇY VE S D İSE N_s ÇD DİR VEYA

R₁₃: EĞER H_s ÇY VE T D VE S D İSE N_s O DUR VEYA

R₁₄: EĞER H_s ÇY VE T O VE S D İSE N_s D DİR VEYA

R₁₅: EĞER H_s ÇY VE T Y VE S D İSE N_s D DİR VEYA

R₁₆: EĞER H_s ÇY VE T ÇY VE S D İSE N_s ÇD DİR VEYA

R₁₇: EĞER H_s D VE T D VE S O İSE N_s D DİR VEYA
 R₁₈: EĞER H_s D VE T O VE S O İSE N_s ÇD DİR VEYA
 R₁₉: EĞER H_s D VE T Y VE S O İSE N_s ÇD DİR VEYA
 R₂₀: EĞER H_s D VE T ÇY VE S O İSE N_s ÇD DİR VEYA

R₂₁: EĞER H_s O VE T D VE S O İSE N_s D DİR VEYA
 R₂₂: EĞER H_s O VE T O VE S O İSE N_s D DİR VEYA
 R₂₃: EĞER H_s O VE T Y VE S O İSE N_s ÇD DİR VEYA
 R₂₄: EĞER H_s O VE T ÇY VE S O İSE N_s ÇD DİR VEYA

R₂₅: EĞER H_s Y VE T D VE S O İSE N_s O DUR VEYA
 R₂₆: EĞER H_s Y VE T O VE S O İSE N_s D DİR VEYA
 R₂₇: EĞER H_s Y VE T Y VE S O İSE N_s D DİR VEYA
 R₂₈: EĞER H_s Y VE T ÇY VE S O İSE N_s ÇD DİR VEYA

R₂₉: EĞER H_s ÇY VE T D VE S O İSE N_s O DUR VEYA
 R₃₀: EĞER H_s ÇY VE T O VE S O İSE N_s D DİR VEYA
 R₃₁: EĞER H_s ÇY VE T Y VE S O İSE N_s D DİR VEYA
 R₃₂: EĞER H_s ÇY VE T ÇY VE S O İSE N_s D DİR VEYA

R₃₃: EĞER H_s D VE T D VE S Y İSE N_s D DİR VEYA
 R₃₄: EĞER H_s D VE T O VE S Y İSE N_s D DİR VEYA
 R₃₅: EĞER H^s D VE T Y VE S Y İSE N_s D DİR VEYA
 R₃₆: EĞER H_s D VE T ÇY VE S Y İSE N_s D DİR VEYA

R₃₇: EĞER H_s O VE T D VE S Y İSE N_s O DUR VEYA
 R₃₈: EĞER H_s O VE T O VE S Y İSE N_s D DİR VEYA
 R₃₉: EĞER H_s O VE T Y VE S Y İSE N_s D DİR VEYA
 R₄₀: EĞER H_s O VE T ÇY VE S Y İSE N_s D DİR VEYA

R₄₁: EĞER H_s Y VE T D VE S Y İSE N_s O DUR VEYA

R₄₂: EĞER H_s Y VE T O VE S Y İSE N_s O DUR VEYA

R₄₃: EĞER H_s Y VE T Y VE S Y İSE N_s D DİR VEYA

R₄₄: EĞER H_s Y VE T ÇY VE S Y İSE N_s D DİR VEYA

R₄₅: EĞER H_s ÇY VE T D VE S Y İSE N_s Y DİR VEYA

R₄₆: EĞER H_s ÇY VE T O VE S Y İSE N_s O DUR VEYA

R₄₇: EĞER H_s ÇY VE T Y VE S Y İSE N_s O DUR VEYA

R₄₈: EĞER H_s ÇY VE T ÇY VE S Y İSE N_s D DİR

Bulanık sistemin girdi ve çıktıların oluşturduğu sözel değişkenlere ait kısaltmalar aşağıda açıklanmıştır:

D: Düşük

O: Orta

Y: Yüksek

ÇY: Çok yüksek

ED: En düşük

ÇD: Çok düşük

EY: En yüksek

EK 3

ADELI-HUNG ALGORİTMA
(AHA)

1. Adım: Girdi vektörleri ile her küme arasındaki öklidyen uzaklığın hesaplanması:

$$D(\mathbf{X}, \mathbf{C}_i) = \sqrt{\sum_{j=1}^M (x_j - c_{ij})^2}$$

$D(\mathbf{X}, \mathbf{C})$: Öklidyen uzaklık

$\mathbf{X}$: Girdi vektörü

$\mathbf{C}$: Grup vektörü

M : Değişken sayısı

x_j : Girdi vektörünün j . değeri

c_{ij} : i . grup vektörünün j . bileşeni

2. Adım: Girdi vektörü için en uygun grubun ($\mathbf{C}_a$) bulunması

$$\mathbf{C}_a = \{ \mathbf{C} \mid \min \{ D(\mathbf{X}, \mathbf{C}_i) \}, i = 1, 2, \dots, P \}$$

3. Adım: Minimum uzaklık önceden belirlenen sınır değer üzerinde ise girdi vektörünün yeni bir grup ($\mathbf{C}_{\text{yeni}}$) olarak atanması

$$\text{eğer } k < \min \{ D(\mathbf{X}, \mathbf{C}_i), i = 1, 2, \dots, P \} \text{ ise } \mathbf{C}_{\text{yeni}} = \mathbf{X}$$

EK 4

BULANIK KURAL TABANI

Bulanık kural tabanına karşılık gelen tüm kurallar için seçilen permeabilite katsayısı (P), eğim ($\cot \theta$) ve dalga sayısı (N) değerlerinin sabit olduğu kabul edilmiş olup örneğin P, $\cot \theta$ ve N değerleri sırasıyla 0,1; 2 ve 3000 seçilen bir bulanık kural tabanını oluşturan bulanık kurallar dizisi aşağıdaki şekilde tanımlanmıştır:

R₁: EĞER H_s D VE T D VE S D İSE N_s O DUR VEYA

R₂: EĞER H_s D VE T O VE S D İSE N_s O DUR VEYA

R₃: EĞER H_s D VE T Y VE S D İSE N_s O DUR VEYA

R₄: EĞER H_s D VE T ÇY VE S D İSE N_s D DİR VEYA

R₅: EĞER H_s O VE T D VE S D İSE N_s O DUR VEYA

R₆: EĞER H_s O VE T O VE S D İSE N_s O DUR VEYA

R₇: EĞER H_s O VE T Y VE S D İSE N_s O DUR VEYA

R₈: EĞER H_s O VE T ÇY VE S D İSE N_s D DİR VEYA

R₉: EĞER H_s Y VE T D VE S D İSE N_s O DUR VEYA

R₁₀: EĞER H_s Y VE T O VE S D İSE N_s O DUR VEYA

R₁₁: EĞER H_s Y VE T Y VE S D İSE N_s O DUR VEYA

R₁₂: EĞER H_s Y VE T ÇY VE S D İSE N_s D DİR VEYA

R₁₃: EĞER H_s ÇY VE T D VE S D İSE N_s O DUR VEYA

R₁₄: EĞER H_s ÇY VE T O VE S D İSE N_s O DUR VEYA

R₁₅: EĞER H_s ÇY VE T Y VE S D İSE N_s O DUR VEYA

R₁₆: EĞER H_s ÇY VE T ÇY VE S D İSE N_s D DİR VEYA

R₁₇: EĞER H_s D VE T D VE S O İSE N_s O DUR VEYA

R₁₈: EĞER H_s D VE T O VE S O İSE N_s O DUR VEYA

R₁₉: EĞER H_s D VE T Y VE S O İSE N_s O DUR VEYA

R₂₀: EĞER H_s D VE T ÇY VE S O İSE N_s D DİR VEYA

R₂₁: EĞER H_s O VE T D VE S O İSE N_s O DUR VEYA

R₂₂: EĞER H_s O VE T O VE S O İSE N_s O DUR VEYA

R₂₃: EĞER H_s O VE T Y VE S O İSE N_s O DUR VEYA

R₂₄: EĞER H_s O VE T ÇY VE S O İSE N_s D DİR VEYA

R₂₅: EĞER H_s Y VE T D VE S O İSE N_s O DUR VEYA

R₂₆: EĞER H_s Y VE T O VE S O İSE N_s O DUR VEYA

R₂₇: EĞER H_s Y VE T Y VE S O İSE N_s O DUR VEYA

R₂₈: EĞER H_s Y VE T ÇY VE S O İSE N_s D DİR VEYA

R₂₉: EĞER H_s ÇY VE T D VE S O İSE N_s O DUR VEYA

R₃₀: EĞER H_s ÇY VE T O VE S O İSE N_s O DUR VEYA

R₃₁: EĞER H_s ÇY VE T Y VE S O İSE N_s O DUR VEYA

R₃₂: EĞER H_s ÇY VE T ÇY VE S O İSE N_s D DUR VEYA

R₃₃: EĞER H_s D VE T D VE S Y İSE N_s Y DİR VEYA

R₃₄: EĞER H_s D VE T O VE S Y İSE N_s Y DİR VEYA

R₃₅: EĞER H^s D VE T Y VE S Y İSE N_s Y DİR VEYA

R₃₆: EĞER H_s D VE T ÇY VE S Y İSE N_s Y DİR VEYA

R₃₇: EĞER H_s O VE T D VE S Y İSE N_s Y DİR VEYA

R₃₈: EĞER H_s O VE T O VE S Y İSE N_s Y DİR VEYA

R₃₉: EĞER H_s O VE T Y VE S Y İSE N_s Y DİR VEYA

R₄₀: EĞER H_s O VE T ÇY VE S Y İSE N_s Y DİR VEYA

R₄₁: EĞER H_s Y VE T D VE S Y İSE N_s Y DİR VEYA
 R₄₂: EĞER H_s Y VE T O VE S Y İSE N_s Y DİR VEYA
 R₄₃: EĞER H_s Y VE T Y VE S Y İSE N_s Y DİR VEYA
 R₄₄: EĞER H_s Y VE T ÇY VE S Y İSE N_s Y DİR VEYA

R₄₅: EĞER H_s ÇY VE T D VE S Y İSE N_s ÇY DİR VEYA
 R₄₆: EĞER H_s ÇY VE T O VE S Y İSE N_s ÇY DİR VEYA
 R₄₇: EĞER H_s ÇY VE T Y VE S Y İSE N_s ÇY DİR VEYA
 R₄₈: EĞER H_s ÇY VE T ÇY VE S Y İSE N_s ÇY DİR

Bulanık sistemin girdi ve çıktılarını oluşturan sözel değişkenlere ait kısaltmalar aşağıda açıklanmıştır:

D: Düşük
 O: Orta
 Y: Yüksek
 ÇY: Çok yüksek

ÖZGEÇMİŞ

Anadolu Üniversitesi Mühendislik Mimarlık Fakültesi İnşaat Mühendisliği Bölümünden Lisans (1993); Gazi Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Ana Bilim Dalından Yüksek Lisans derecesi aldı (1998). Cumhuriyet Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümünde Araş. Görevlisi olmakla birlikte halen lisansüstü eğitimini tamamlamak üzere Gazi Üniversitesi Fen Bilimleri Enstitüsünde görevlendirilmiş olarak çalışmalarına devam etmektedir.

