

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

YÜKSEK LİSANS TEZİ

**YÜKSEK ISIYA MARUZ BETONARME DÖŞEMELERİN EĞİLME
KAPASİTESİNİN HESABINDA YAPAY VE BULANIK SİNİR AĞI
YAKLAŞIMI**

Mihriban KARAMANOĞLU

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

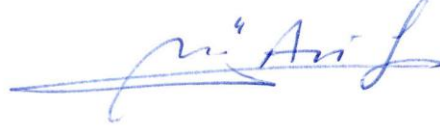
**ŞANLIURFA
2010**

Yrd. Doç. Dr. Mahmut BİLGEHAN danışmanlığında, Mihriban KARAMANOĞLU'nun hazırladığı “Yüksek Isıya Maruz Betonarme Döşemelerin Eğilme Kapasitesinin Hesabında Yapay ve Bulanık Sinir Ağı Yaklaşımı” konulu bu çalışma 10/12/2010 tarihinde aşağıdaki jüri tarafından İnşaat Mühendisliği Anabilim Dalı'nda Yüksek Lisans tezi olarak kabul edilmiştir.

Danışman : Yrd. Doç. Dr. Mahmut BİLGEHAN



Üye : Doç. Dr. M. Arif GÜREL



Üye : Doç. Dr. Hüsamettin BULUT



Bu Tezin İnşaat Mühendisliği Anabilim Dalında Yapıldığını ve Enstitümüz Kurallarına Göre Düzenlendiğini Onaylarım.



Prof. Dr. Mehmet Cici Y.
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

	Sayfa No
ÖZ	i
ABSTRACT	ii
TEŞEKKÜR	iii
ŞEKİLLER DİZİNİ	iv
ÇİZELGELER DİZİNİ	v
SİMGELER DİZİNİ	vi
1. GİRİŞ	1
2. ÖNCEKİ ÇALIŞMALAR	4
3. MATERYAL ve YÖNTEM	10
3.1. Materyal	10
3.1.1. Yangına maruz betonarme döşemelerin taşıma gücü moment kapasiteleri	11
3.1.2. Sıcaklık-zaman ilişkisi	11
3.1.3. Yüksek ısı altında beton basınç dayanımı	11
3.1.4. Yüksek ısı altında çelik çekme dayanımı	12
3.1.5. Plak döşemede sürekli rejimde ısı iletimi	13
3.1.6. Yüksek ısıya maruz betonarme döşemenin moment kapasitesi	15
3.2. Yöntem	17
3.2.1. Yapay sinir ağları	17
3.2.1.1. Yapay sinir ağlarının genel özellikleri	23
3.2.1.2. Yapay sinir ağlarının dezavantajları	25
3.2.1.3. Yapay sinir ağlarının yapısı	26
3.2.1.4. Yapay sinir ağlarının sınıflandırılması	27
3.2.1.5. Uygulanan YSA modeli	29
3.2.2. Bulanık sinir ağları	31
3.2.2.1. ANFIS mimarisi	33
4. ARAŞTIRMA BULGULARI ve TARTIŞMA	37
5. SONUÇLAR ve ÖNERİLER	44
5.1. Sonuçlar	44
5.1.1. Döşemenin faydalı yüksekliğinin moment kapasitesi üzerindeki etkisi	44
5.1.2. Farklı donatı alanlarının moment kapasitesi üzerindeki etkisi	45
5.1.3. Farklı donatı dayanımlarının moment kapasitesi üzerindeki etkisi	45
5.1.4. Farklı beton dayanımlarının moment kapasitesi üzerindeki etkisi	46
5.1.5. Farklı pas paylarının moment kapasitesi üzerindeki etkisi	47
5.2. Öneriler	49
KAYNAKLAR	50
ÖZGEÇMİŞ	53
ÖZET	54
SUMMARY	56

ÖZ

Yüksek Lisans Tezi

YÜKSEK ISIYA MARUZ BETONARME DÖŞEMELERİN EĞİLME KAPASİTESİNİN HESABINDA YAPAY VE BULANIK SİNİR AĞI YAKLAŞIMI

Mihriban KARAMANOĞLU

Harran Üniversitesi
Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Mahmut BİLGEHAN
Yıl: 2010, Sayfa: 57

Yangına maruz olan diğer betonarme elemanlar gibi döşemeler de yangından oldukça etkilenmektedir. Yüksek sıcaklıkta betonarme elemanların dayanımı azaldığından dolayı, betonarme döşemelerin taşıma gücü moment kapasiteleri de azalmaktadır. Bu tez çalışmasında, Yapay Sinir Ağı (YSA) ve Bulanık Sinir Ağı kullanılarak yangına maruz betonarme döşemelerin taşıma gücü moment kapasitelerinin belirlenebilmesi için bir tahmin modeli araştırılmış ve geliştirilmiştir. Yangına maruz betonarme döşemelerin hesaplanmış olan moment kapasiteleri ANFIS (Adaptive Neuro-Fuzzy Inference System) modeli ile tahmin edilmiş ve geliştirilen ANFIS modelinin tahmin etme kapasitesi araştırılmıştır. Farklı yangın etkime sürelerine maruz kalan farklı özellikteki betonarme döşemelerin eğilme kapasiteleri hesaplanırken yangının etkime süresine bağlı olarak ortaya çıkan yüksek sıcaklık ISO834 (1975)'de verilen ve zamanın fonksiyonu olarak tanımlanan bağıntı ile hesaplanmakta ve sıcaklığın döşeme içerisindeki dağılımı sürekli rejimde bir boyutlu ısı geçişi kabulü ile belirlenmektedir. Döşeme dilimlere ayrılmakta, yangının etkime süresine bağlı olarak dilimlerde oluşan sıcaklık belirlenmekte ve Eurocode 2 (1995)'deki azaltma katsayıları kullanılarak ortaya çıkan sıcaklık altındaki malzeme dayanımları ve kuvvetler hesaplanmaktadır. Kuvvetlerin dengesinden ise döşemenin eğilme kapasitesi elde edilmektedir. Bu yöntemle elde edilen verilerden bir veri kümesi oluşturulmuştur. Bu veri kümesinin %55'i eğitim aşamasında, %45'i ise test aşamasında kullanılmıştır. Elde edilen sonuçlar kurulan yapay ve bulanık sinir ağı modelinin yangına maruz betonarme döşemelerin eğilme kapasitesini tahmin etme kabiliyetini ortaya koymaktadır. Ayrıca yapay ve bulanık sinir ağı modelleri ile elde edilen sonuçlar karşılaştırılmıştır. Yapay sinir ağı modelinin, bulanık sinir ağı modeline göre daha iyi sonuçlar verdiği görülmektedir.

ANAHTAR KELİMELER : döşeme, yangın, taşıma gücü momenti, yapay sinir ağları, ANFIS

ABSTRACT

MSc Thesis

ARTIFICIAL NEURAL NETWORKS AND NEURO-FUZZY APPROACHES IN PREDICTION OF THE MOMENT CAPACITY OF REINFORCED CONCRETE SLABS IN HIGH TEMPERATURE

Mihriban KARAMANOĞLU

**Harran University
Graduate School of Natural and Applied Sciences
Department of Civil Engineering**

**Supervisor: Assist. Prof. Dr. Mahmut BİLGEHAN
Year: 2010, Page: 57**

Reinforced concrete slabs like the other reinforced concrete elements exposed to fire are also heavily influenced by fire. Since the strength of reinforced concrete elements under high temperatures is reduced, ultimate moment capacity of reinforced concrete slab is also reduced. In this thesis, the prediction model using Neuro-Fuzzy and Artificial Neural Networks (ANN) to predict the ultimate moment capacity of reinforced concrete slabs in fire is investigated and developed. The calculated moment capacity of reinforced concrete slabs in fire is estimated by ANFIS (Adaptive Neuro-Fuzzy Inference System) model and the prediction capacity of evaluated ANFIS model is investigated. Calculating the flexural capacity of reinforced concrete slabs with different properties exposed to different fire effect time, emerging high temperature depending on the effect duration of fire is calculated by formula given and also defined as a function of time in ISO834 (1975). Temperatures in slices inside section of slab are obtained by formulas in one dimensional steady heat transfer. The slab is divided into slices for analysis, depending on effective time of fire the temperature in which slices is determined, and resistance of the material and forces in occurred temperature by using reduced coefficients in Eurocode 2 (1995) are calculated. The bending capacity of the slab was obtained from the balance of the forces. The data set was created from data obtained from this method. 55% and 45% of this set of data were used in the training and the testing phase, respectively. The results obtained shows that considered artificial neural networks and neuro-fuzzy model are able to predict ultimate moment capacity of reinforced concrete slabs in fire. Also, on this thesis results obtained with the artificial neural networks and neuro-fuzzy model are compared. It is seen that the considered artificial neural network model gives better results than the considered neuro-fuzzy model.

KEYWORDS : slab, fire, ultimate moment capacity, artificial neural networks, ANFIS

TEŐEKKÜR

Yüksek lisans tez çalışmam süresince, akademik alandaki bilgi ve birikimlerini esirgemeyerek bana yardımcı olan ve yol gösteren danışmanım Yrd. Doç. Dr. Mahmut BİLGEHAN'a ve sevgili eşine, her zaman yanımda olan ve beni destekleyen sevgili aileme maddi ve manevi desteklerinden dolayı teşekkür ederim.

ŞEKİLLER DİZİNİ

	Sayfa No
Şekil 3.1. Beton ve çelik malzemesi için dayanım azaltma katsayıları (Erdem, 2008b; revize edilmiştir)	13
Şekil 3.2. Betonarme döşemede ısı iletimi	14
Şekil 3.3. Betonarme döşemede yangına maruz kalma süresine bağlı olarak oluşan sıcaklık dağılımı	15
Şekil 3.4. Döşeme içerisindeki sıcaklık değişimi ve oluşan kuvvetler (Erdem, 2008b; revize edilmiştir)	16
Şekil 3.5. Biyolojik nöronun yapısı (http://bilimge.com/index.php/component/content/article/68-yapay-sinir-aglari/830-yapay-sinir-aglari.html)	19
Şekil 3.6. Yapay nöronun yapısı (Yurtoğlu, 2005).....	21
Şekil 3.7. En çok kullanılan transfer fonksiyonları (Yurtoğlu, 2005)	22
Şekil 3.8. Çok girişli N nöronlu hücre modeli (Çetin ve ark., 2006).....	23
Şekil 3.9. Genel bir YSA yapısı	26
Şekil 3.10. İleri ve geri beslemeli ağ yapısı (Yurtoğlu, 2005).....	28
Şekil 3.11. Geliştirilen YSA mimarisi.....	30
Şekil 3.12. Sugeno bulanık modeli için bulanık çıkarım sistemi (Özçalık ve Uygur, 2003).....	34
Şekil 3.13. ANFIS mimarisi (Özçalık ve Uygur, 2003)	34
Şekil 4.1. Moment kapasitesinin tahmini için kullanılan eğitim ve test verileri.....	37
Şekil 4.2. Hesaplanan ve YSA modeli ile tahmin edilen moment kapasite değerleri (Eğitim aşaması için).....	38
Şekil 4.3. Hesaplanan ve YSA modeli ile tahmin edilen moment kapasite değerleri (Test aşaması için)	38
Şekil 4.4. Hesaplanan ve YSA modeli ile tahmin edilen moment kapasitelerinin karşılaştırılması (Eğitim aşaması için).....	39
Şekil 4.5. Hesaplanan ve YSA modeli ile tahmin edilen moment kapasitelerinin karşılaştırılması (Test aşaması için).....	39
Şekil 4.6. Hesaplanan ve ANFIS modeli ile tahmin edilen moment kapasite değerleri (Eğitim aşaması için).....	40
Şekil 4.7. Hesaplanan ve ANFIS modeli ile tahmin edilen moment kapasite değerleri (Test aşaması için)	40
Şekil 4.8. Hesaplanan ve ANFIS modeli ile tahmin edilen moment kapasitelerinin karşılaştırılması (Eğitim aşaması için).....	41
Şekil 4.9. Hesaplanan ve ANFIS modeli ile tahmin edilen moment kapasitelerinin karşılaştırılması (Test aşaması için).....	41
Şekil 4.10. Hesaplanan moment değerlerinin eğitim aşamasında tahmin edilen moment değerleriyle karşılaştırılması	42
Şekil 4.11. Hesaplanan moment değerlerinin test aşamasında tahmin edilen moment değerleriyle karşılaştırılması	42
Şekil 5.1. Faydalı yüksekliğin moment taşıma kapasitesi üzerindeki etkisi.....	44
Şekil 5.2. Farklı donatı alanlarının moment taşıma kapasitesi üzerindeki etkisi	45
Şekil 5.3. Farklı donatı dayanımlarının moment taşıma kapasitesi üzerindeki etkisi	46
Şekil 5.4. Farklı beton dayanımlarının moment taşıma kapasitesi üzerindeki etkisi	47
Şekil 5.5. Farklı pas paylarının moment taşıma kapasitesi üzerindeki etkisi	48

ÇİZELGELER DİZİNİ

	Sayfa No
Çizelge 3.1. YSA ile sinir sistemi arasındaki yapısal benzerlikler	19
Çizelge 5.1. Elde edilen global istatistiksel değerler	43

SİMGELER DİZİNİ

T	Yangının etkime süresine bağlı olarak oluşan sıcaklık
t	Yangının etkime süresi
T_a	Ortam ısısı
k_c	Beton basınç dayanımı azaltma katsayısı
σ_{CT}	Betonun lokal (artan sıcaklıktaki) basınç dayanımı
$\sigma_{C20^{\circ}C}$	20°C'deki beton basınç dayanımı
k_s	Çelik çekme dayanımı azaltma katsayısı
f_{suT}	Çeliğin lokal (artan sıcaklıktaki) çekme dayanımı
$f_{su20^{\circ}C}$	20°C'deki çelik çekme dayanımı
Q	Isı iletim oranı
A	Döşemenin yüzey alanı
$T_{\infty 1}, T_{\infty 2}$	İçinde ısı iletimi olmayan döşemenin iki yüzündeki sıcaklıklar
T_1	Döşemenin yangına maruz kalan yüzeyindeki sıcaklık
T_2	Döşemenin yangına maruz kalmayan yüzeyindeki sıcaklık
h	Döşeme yüksekliği
h_1, h_2	Isı taşınım katsayıları
k	Betonun ısı iletim katsayısı
R_t	Toplam ısı direnci
y	Döşeme içerisindeki herhangi bir nokta
$T_{(y)}$	Döşeme içerisinde herhangi bir noktadaki sıcaklık
D	Döşemeyi dilimlere ayırma sayısı
F_s	Donatının çekme kuvveti
k_{s_i}	i. dilimdeki çelik çekme dayanımı azaltma katsayısı
f_{yd}	Donatının 20 °C sıcaklığındaki akma dayanımı
A_{s_i}	i. dilimdeki donatı alanı
F_c	Beton basınç kuvveti
f_{cd}	Betonunu 20 °C sıcaklığındaki basınç dayanımı
k_{c_i}	i. dilimdeki beton basınç dayanımı azaltma katsayısı
Δy	Her bir döşeme diliminin yüksekliği (kalınlığı)
a	Basınç gerilme bloğunun derinliği
M_u	Döşemenin nihai eğilme momenti kapasitesi
d	Döşeme faydalı yüksekliği
d'	Döşeme pas payı
i	Dilim sırası
$O_{n,i}$	n. katmandaki i. düğümün çıkışı
$\mu_{A_i}(x)$	A'nın i. düğümdeki üyelik derecesi
$\mu_{B_i}(y)$	B'nin i. düğümdeki üyelik derecesi

w_i	i. düğüme gelen sinyallerin çarpımı
$\overline{w_i}$	i. düğümün ateşleme seviyesi
$\overline{w_i f_i}$	i. düğümün çıkış değeri
O_i	i. verinin hesaplanmış moment kapasitesi değeri
P_i	i. verinin sinir ağı modeliyle tahmin edilen moment kapasitesi değeri
N	Sinir ağının eğitim ve test aşamalarında kullanılan veri sayısı
R	Korelasyon katsayısı
$RMSE$	Karesel hataların ortalama karekökü
MBE	Ortalama taraflı hata

1. GİRİŞ

Dünyada olduğu gibi, ülkemizde de betonarme yapıların kullanımı oldukça yaygındır. Bu yapılarda çeşitli nedenlerle yangınlar çıkabilmekte, bu yangınlar yapıların kullanılamaz hale gelmesine ve birçok insanın hayatını kaybetmesine sebep olmaktadır. Bu noktada yapıların yangın dayanımı ve yangın güvenliği büyük bir önem kazanmaktadır. Yangın dayanımı, yapının belirli bir yangın yükü altında kendisinden beklenen görevleri yerine getirmeye devam ettiği zaman süresidir (Kılıç, 2008).

11 Eylül 2001 tarihinde İkiz Kuleler olarak bilinen New York World Trade Center'da (New York Dünya Ticaret Merkezi) meydana gelen korkunç felaket tüm insanların dikkatini çekmiş ve ardından yapıların yangın dayanımı, birçok bilimsel araştırmacının odak noktası haline gelmiştir.

11 Eylül 2001 tarihinde New York Dünya Ticaret Merkezi'nin 110'ar katlı İkiz Kulelerine iki uçağın çarpmasıyla gerçekleşen saldırıda, kulelerden kuzeyde bulunan kulenin 94.-98. katları arasına uçak çarptıktan yaklaşık 17 dakika sonra ikinci bir uçak güney kulenin 77.-85. katları arasına çarpmıştır. Uçaklardaki yakıtın etkisiyle çarpmanın hemen ardından her iki kulede de yangın başlamıştır. İkinci uçağın çarptığı güney kule, çarpmadan 56 dakika sonra çökmüş ve hemen peşinden kuzey kule, ilk uçağın çarpmasından 102 dakika sonra yıkılmıştır.

11 Eylül 2001 tarihinde New York Dünya Ticaret Merkezi'ne yapılan saldırıda, İkiz Kulelerin yıkılmasına sebep olan esas faktör ya da faktörlerin neler olduğuna dair yapılan tartışmalar halen devam etmektedir. İkiz Kulelerin yıkılmasına sebep olan faktörlerin neler olduğuna dair uzmanların vardığı ortak bir görüş yoktur. Bu konuda birçok araştırmacı ve uzman farklı görüş ileri sürmüştür. Bazı uzmanlar, uçak çarpması sonrasında başlayan yangının uzun süre devam etmesi ile ortaya çıkan

yüksek sıcaklık sonucunda çelik kolonların taşıma gücü özelliğini kaybederek üst katlardaki yapının ağırlığını taşıyamadığı ve kulelerin çöktüğü görüşünü savunurken; diğerleri, yangının daha sonra başladığı güney kulenin daha önce yıkılması ve kulenin yan yatmadan olduğu yere yıkılmasının düşündürücü olduğu görüşünü savunmaktadır.

Dünyanın önemli deprem kuşaklarından biri olan ülkemizde, deprem sonrasında çıkabilecek yangınların riski de fazladır. 17 Ağustos 1999'da yaşanan Marmara depremi bunun örneklerinden biridir. 17 Ağustos depreminden sonra günlerce süren bir rafineri yangını başlamıştır.

1995 yılında Japonya'yı son elli yılda vuran depremlerin en şiddetlisi olan Kobe depreminde, çöken binalar ve depremden sonra başlayan yangınlar sebebiyle yaklaşık 5400 kişi hayatını kaybetmiştir.

Bir yapının yangına karşı direncini, yapının taşıyıcı sistem elemanlarının direnci belirler. Yangına maruz olan diğer betonarme elemanlar gibi döşemeler de yangından oldukça etkilenmektedir. Yüksek sıcaklıkta betonarme elemanların dayanımı azaldığından dolayı, betonarme döşemelerin taşıma gücü moment kapasiteleri de azalmaktadır. Yangına maruz betonarme döşemelerin moment kapasitelerini hesaplayabilmek için yangına maruz kalma süresine bağlı olarak artan sıcaklık, döşeme içerisindeki ısı dağılımı, en kesit ve malzeme özellikleri, oluşturulan dilimlerdeki çekme ve basınç kuvvetleri, eşdeğer dikdörtgen gerilme bloğu derinliği, iç kuvvetlerin dengesi gibi parametreler belirlenmelidir. Bu parametreleri elde etmek için çok sayıda hesaplama yapmak gerektiği bilinmektedir. Karmaşık sayısal hesaplamalardan kurtulmak için bu parametreleri etkin bir biçimde tahmin etmekte yapay ve bulanık sinir ağı modeli kullanılabilir. Bazı çalışmalarda Yapay Sinir Ağı (YSA) kullanılarak moment kapasitelerinin modellenmesi ile ilgili çalışmalar yapılmış ise de Bulanık Sinir Ağı (BSA) ile ilgili bir çalışmaya rastlanmamıştır.

YSA aslında insan beyninin öğrenme yeteneğini taklit eden bir bilgisayar modelidir. Çok sayıda verinin olduğu karmaşık problemlere uygulanabilen bir tekniktir. Karmaşık fiziksel yöntemlerle ilgili bilgi gerektirmez. Bununla birlikte, bir veri kümesindeki ilişkileri tanımlayabilmektedir. Bundan dolayı YSA yaklaşımı, geleneksel matematiksel çözümlerin uygun olmadığı problemlerde uygulanabilmektedir.

Bu çalışmada, yapay ve bulanık sinir ağları kullanılarak yangına maruz betonarme döşemelerin taşıma gücü moment kapasiteleri için bir tahmin modeli geliştirilmiştir. Yangına maruz betonarme döşemelerin hesaplanmış olan moment kapasiteleri YSA modeli ve ANFIS (Adaptive Neuro-Fuzzy Inference System) modeli ile tahmin edilmiştir. Ayrıca bu çalışmada, yangına maruz betonarme döşemelerin taşıma gücü momentlerini belirlemek için YSA ve ANFIS modelinin tahmin etme kapasitesi araştırılmaktadır.

2. ÖNCEKİ ÇALIŞMALAR

Tez çalışmasının bu bölümünde, YSA ve/veya BSA modelinin kullanıldığı bazı çalışmalar özetlenmiştir. Ayrıca bu bölümün son kısmında, yüksek ısı etkisinin beton veya betonarme elemanlara etkisini araştıran çalışmaları kapsayan bir literatür özeti verilmiştir.

Lee (2003), beton basınç dayanımının belirlenmesi üzerine yapmış olduğu çalışmada, beton basınç dayanımının tahmin edilmesi için bir yapay zeka sistemi geliştirmiştir. Bu amaçla YSA'dan faydalanmıştır. Geliştirdiği modelin etkin bir şekilde deneysel verilere yakın sonuçlar elde etmesinin yanı sıra, yeni değerler üretebilmesinin de önemli bir avantaj olduğunu vurgulamıştır.

Akbulut ve ark. (2004), geliştirdikleri sinirsel bulanık sistemi, betonarme inşaatlarında kullanılan kumların nemlilik dereceleri ve kesme modüllerinin tahmin edilmesinde kullanmıştır. Uygulamada YSA için klasik geri beslemeli sistem kullanılmıştır. Çalışma sonucunda sinirsel bulanık sistem ile çoklu regresyon analiz sonuçları karşılaştırılmış ve sinirsel bulanık sistemin daha uygun sonuçlar verdiği belirtilmiştir.

Özsoy ve Fırat (2004), kirişsiz döşemeli betonarme bir binada çeşitli parametrelere bağlı olarak meydana gelen yatay ötelenme değerinin YSA ile tahmin edilmesi üzerine bir çalışma gerçekleştirmiştir. YSA ile yapılan yatay deplasman tahminleri, SAP2000 programından alınan yatay deplasman verileri ile karşılaştırılmış ve elde edilen sonuçların birbirine çok yakın olmasından dolayı, YSA ile yatay deplasmanların başarılı bir şekilde tahmin edilebileceği vurgulanmıştır.

Hola ve Schabowicz (2005), tahribatsız yöntemlerle belirlenen beton basınç dayanımının YSA ile belirlenmesi üzerine bir çalışma yapmıştır. YSA'nın eğitilmesi

ve test edilmesi için, 7 farklı beton türünün laboratuvar testlerinden elde edilen sonuçlar kullanılarak bir deneysel veri kümesi tanımlanmıştır. Bu veriler, 150×150×150 ebatlarındaki beton numunelerin 3, 7, 14, 21, 28 ve 90 gün kürlendikten sonra tahribatsız laboratuvar testleriyle ve tahribatlı yöntemlerle belirlenen beton basınç dayanım değerlerinden oluşmaktadır. Oluşturulan veri kümesinde, 24 MPa'dan 105 MPa'ya kadar sıralanan beton basınç dayanımı değerleri bulunmaktadır. Veri kümesinin %80'i ağırlık eğitilmesinde, % 20'si ise test edilmesinde kullanılmıştır. Ayrıca yazarlar, beş farklı öğrenme algoritmasını kullanarak deneysel sonuçların analizi için en uygun sinir ağı tipini belirlemeye çalışmıştır. Sonuçlar Levenberg-Marquardt (LM) ağırlık eğitiminin, eğitim verilerini doğru olarak kullandığını ve test verilerini yüksek bir korelasyon katsayısıyla belirlediğini göstermiştir. Ayrıca, en yüksek korelasyon katsayısıyla en doğru sonucu veren LM ağırlık eğitiminin, en düşük devir (epoch) sayısı ile analizi tamamladığı görülmüştür. Sonuç olarak bu çalışma, betonun basınç dayanımının belirlenmesinde YSA'nın oldukça uygun bir yöntem olduğunu göstermiştir.

Topçu ve Sarıdemir (2007), gazbetondan parçalanmış atık agregaları beton üretiminde 4-16 mm ve 16-31.5 mm çaplı iki farklı büyüklüğe sahip kırmataş olarak kullanmıştır. Gazbetonun parçalanması ile elde edilen atık agregalarla oluşturulmuş beton türleri için sertleşmiş betonun birim ağırlığını, silindirik basınç dayanımını ve ultrases hızını deneysel yöntemle belirlemiş ve bu beton türleri için elastisite modülünü hesaplamıştır. Deneysel sonuçlara göre, kırmataş betondan daha hafif olan betonun gazbetondan parçalanmış atık agregalar kullanılarak üretilebileceği ve gazbetondan parçalanmış atık agregaların kullanımının beton üretimi için uygun olduğu görülmüştür. Yazarlar, YSA'yı kullanarak bir model kurmuş ve deneysel sonuçlarla modelin sonuçlarını karşılaştırmıştır. Sonuçta atık agregalı betonun özellikleri deneysel yöntemler olmaksızın elde edilebilmiş, eğitim ve test aşamasındaki sonuçların deneysel sonuçlarla benzer olduğu görülmüştür.

Topçu ve ark. (2008), katkılı çimento için ilave bağlayıcı malzeme olarak optimum puzzolan kullanımını araştırmıştır. Üç farklı doğal puzzolon türü (Eskişehir volkanik sünger taşı, Nevşehir volkanik sünger taşı ve doğal zeolit) ve iki farklı

yapay puzzolan türü (uçucu kül ve yüksek fırın cürufu), katkılı çimento üretimi için klinkerle %10, %20, %30, %40 ve %50 oranında yer değiştirerek kullanılmıştır. Harç numunelerinin dayanım gelişmesi 2, 7, 28 ve 180 günlük deneysel basınç dayanımı sonuçlarına göre belirlenmiştir. Bununla birlikte farklı puzzolan katkılı çimentoların dayanım gelişmeleri, kurdukları bulanık mantık sistemleri ve YSA modelleri ile tahmin edilmeye çalışılmıştır. 61 farklı çimentoyla üretilen 244 harç numunesinin 2, 7, 28 ve 180 günlük basınç dayanımı sonuçları, çok katmanlı ileri beslemeli sinir ağı ve Sugeno tipi bulanık çıkarım modelinin eğitilmesinde ve test edilmesinde kullanılmıştır. Modelin eğitilmesinde ve test edilmesinde numunelerin yaşı, klinker, zeolit, Eskişehir volkanik sünger taşı, Nevşehir volkanik sünger taşı, uçucu kül, yüksek fırınlı cüruf deneysel girdi değişkenleri olarak; basınç dayanımı ise çıktı değişkeni olarak kullanılmıştır. Modeller eğitildikten sonra deneysel girdi değişkenleri kullanılarak testler gerçekleştirilmiştir. Test işleminin sonucunda, basınç dayanımı değerlerinin deneysel sonuçlara benzer tahmin edildiği görülmüştür.

Karahan ve ark. (2008), uçucu kül içeren çelik fiberli betonarmenin uzun dönemdeki dayanım özelliklerinin tahmini için YSA yaklaşımı konulu bir çalışma yapmış ve uçucu kül içeren çelik lifli betonarmenin dayanım özelliklerini araştırmak için bir YSA modeli tasarlamıştır. Bu çalışmada, ağırlığın % 0, % 15 ve % 30'u uçucu kül, hacmin %0.5, %1 ve %1.5'u lif olacak şekilde karışımlar hazırlanmıştır. Standart koşullar altında 7, 28, 90 ve 365 gün kür işlemi uygulandıktan sonra her bir karışım numunesi, basınç ve eğilme dayanımının belirlenmesi için test edilmiştir. Betonun basınç ve eğilme dayanımı çıktı değişkenleri olarak seçilirken; çimentonun miktarı, uçucu külün değişimi, kum, çakıl, çelik fiber ve numunelerin yaşı girdi değişkenleri olarak seçilmiştir. En iyi yaklaşımın belirlenmesi için ağ mimarisinde LM, Scaled Conjugate Gradient (SCG) ve Fletcher-Powell Conjugate Gradient (CGF) algoritması olmak üzere üç farklı algoritma kullanılmıştır. Deneysel sonuçlarla modelden elde edilen sonuçlar karşılaştırılmış ve en uygun algoritmanın LM algoritması olduğu görülmüştür. Ayrıca yazarlar, deneyde kullanılan parametrelerin, bu karışımların dayanımları üzerindeki etkilerinin ne kadar önemli olduğunu belirlemek için varyans analizi metodunu kullanmıştır. Bu çalışma, beton basınç dayanımındaki en etkili parametrelerin sırasıyla (azalan sırayla) zaman, uçucu

kül miktarı ve çelik fiber miktarı; beton eğilme dayanımındaki en etkili parametrelerin ise sırasıyla (azalan sırayla) çelik fiber miktarı, uçucu kül miktarı ve zaman olduğunu ortaya koymuştur.

Bilgehan ve Turgut (2010a), farklı yaşlara sahip betonarme binalardan alınan beton karot numunelerinin basınç dayanımlarını laboratuvar ortamında test etmiştir. Ayrıca ultrason cihazı ile okumalar alınmıştır. Elde edilen datalar kullanılarak, ultrason okumaları girdi olarak; beton basınç dayanımları ise çıktı olarak kullanılmıştır. Sonuçlar, YSA modelinin beton basınç dayanımını tahmin edebilme kapasitesini ortaya koymuştur.

Bilgehan ve Turgut (2010b), beton basınç dayanımını tahmin edebilmek için, ultrason değerleri yanında betonun yoğunluğunu da girdi olarak dikkate alan, basınç dayanımını ise yine çıktı olarak kullanan bir YSA mimarisi kurmuştur. Oluşturulan ağ mimarisinin oldukça uygun sonuçlar verdiği görülmüştür.

Bilgehan (2010), ultrason hızı ve yoğunluğunu girdi olarak, beton basınç dayanımını ise çıktı olarak kullanan yeni bir YSA mimarisi ile BSA modelini dikkate alan karşılaştırmalı bir çalışma yapmıştır. Yazar BSA modelinin, YSA'ya kıyasla daha uygun sonuçlar verdiğini gözlemiştir.

Beton veya betonarme elemanlara yüksek ısı etkisini inceleyen bazı çalışmalar aşağıda özetlenmiştir.

Erdem (2008a), yangına maruz donatılı betonarme kirişlerin performansını araştırmıştır. En kesiti uygun sayıda parçalara bölmüş ve en kesitteki ısı dağılımını, sonlu farklar metodunu kullanan bir bilgisayar programı ile hesaplamıştır. Yangına maruz betonarme kirişin nominal moment kapasitesini kiriş parçalarındaki kuvvetlerin dengesinden elde etmiştir. Yazar ayrıca bu çalışmada, soğuk su sirkülasyonunun ve beton kaplamanın, yangın altında nominal moment kapasitesi üzerindeki avantajını incelemiştir. Sonuçlar beton kaplamanın, betonarme kirişin yangına karşı direncinde önemli olduğunu ortaya koymuştur. Ayrıca soğuk hava

sirkülasyonunun, yangına maruz betonarme kirişin malzeme dayanımları ve moment kapasitesi üzerinde oldukça etkili olduğunu, kirişin moment kapasitesini önemli ölçüde iyileştirdiğini göstermiştir.

Erdem (2010), bir diğer çalışmasında yangına maruz betonarme döşemelerin moment kapasitelerini tahmin edebilmek için bir YSA modeli geliştirmiştir. Geliştirilen YSA modelinde ağırlık eğitilmesi ve test edilmesi için 294 veri kullanılmıştır. Yedi farklı parametreye bağlı olarak moment kapasitesini tahmin eden modelin ürettiği sonuçlar, yangına maruz betonarme döşemelerin kapasitesinin belirlenmesinde modelin oldukça başarılı olduğunu ve yüksek bir doğruluk oranıyla tahminler ürettiğini göstermiştir.

Chen ve ark. (2009), farklı periyotlarda kür edilmiş ve yüksek sıcaklığa maruz kalmış betonların basınç ve yarmada çekme dayanımlarını elde etmiştir. Kür süresi, maksimum sıcaklık ve soğutma tipinin beton dayanımı üzerindeki etkisini araştırmıştır. Yaptıkları bu deneysel çalışma, 800 °C'ye kadar, yüksek ısıya maruz kaldıktan sonra 28 gün kürlenmiş taze betonun, dayanımının %80'ini geri kazanabildiğini ve sıcaklık 200 °C ya da 400 °C iken geri kazanılmış dayanımın kontrol numunelerinin dayanımından yüksek olabildiğini göstermiştir. Üç gün kürlenmiş betonun dayanımını en çok geri kazanan beton olduğunu ve bunu sırasıyla 7 gün, 14 gün ve 1 gün kürlenmiş beton numunelerinin takip ettiği gözlemlenmiştir. Soğutma tipinin de yarmada çekme dayanımı ve basınç dayanımını geri kazanma seviyesini etkilediği kanıtlanmıştır. Bu çalışma, 800 °C'nin altındaki sıcaklıklara maruz kaldığında su püskürtme yoluyla soğutulmuş taze betonun geri kazandığı dayanımın, havada soğutulmuş betonun geri kazandığı dayanımdan daha yüksek olduğunu; ayrıca, maksimum sıcaklık 800 °C'yi aştığında su püskürtme yoluyla soğutulmuş tüm numunelerin dayanım değerlerinin, havada soğutulmuş numunelerinkinden daha düşük olduğunu göstermiştir.

Xu ve Wu (2009), 4 tane tam ölçekli L kesitli, 4 tane T kesitli, 4 tane + kesitli ve 1 tane kare kesitli betonarme kolonun ısı direncini, ISO 834 standardını kullanarak deneysel olarak araştırmıştır. Eksenel yük oranı etkisi, yüksek ısıya maruz

kalma, eksenel deformasyon ve kolonların ısı direnci analiz edilmiştir. Araştırmacıların bu çalışmasında deneysel sonuçlar, eksenel yük oranı 0.55 olduğunda, her kenarı yüksek ısıya maruz T, L ve + kesitli kolonların ısı direncinin kare kesitli kolonun ısı direncinin % 60-73 arasında olduğunu göstermiştir. Numunelerin her kenarının yüksek ısıya maruz olması durumunda, farklı kesite sahip kolonların ısı direncinin, sırasıyla L, T ve + kesite doğru arttığı görülmüştür. Yazarlar T, L ve + kesitli kolonların ısı direncini, deformasyonunu ve sıcaklığını hesaplamak için bir bilgisayar programı geliştirmiştir. Sayısal benzeşimin sonuçları, bu tam ölçekli ısı direnci testleriyle karşılaştırılmıştır. Yapılan bu çalışmayla, her kenarı yüksek ısıya maruz, eksenel yük oranı 0.55 olan ve karesel kesitli olmayan dört kolonun ısı direncinin, kare kesitli kolonun ısı direncinin %60 ile %73'ü arasında sıralanmakta olduğu; eksenel yük oranı ve yüksek ısıya maruz kalma durumunun, karesel kesitli olmayan betonarmenin ısı direnci üzerinde önemli bir etkisi olduğu ortaya konulmuştur.

Ellobody ve Bailey (2009), yangına maruz birbirine bağlanmamış ardgerilmeli beton döşemelerin modellenmesi üzerine bir araştırma yapmıştır.

Bailey ve Ellobody (2009a), diğer bir çalışmasında farklı özellikteki birbirine bağlı tek açıklıklı ardgerilmeli beton döşemelerin yangın direncini araştırmak için bir dizi test yapmış ve farklı malzeme özelliklerinin yangın direnci üzerindeki etkisini araştırmıştır.

Bailey ve Ellobody (2009b), bir diğer çalışmasında ise ardgerilmeli beton döşemelerin yangına maruz kaldığı durumda tüm yapının davranışını araştırmıştır.

Tanyıldızı (2009) ise yaptığı bir çalışmada yüksek ısıya maruz hafif betonun mekanik özelliklerinin tahmini için bir bulanık mantık modeli geliştirmiştir.

3. MATERYAL ve YÖNTEM

Bu tez çalışmasında, yüksek sıcaklığa maruz betonarme döşemelerin eğilme kapasitelerinin belirlenebilmesi için yapay ve bulanık sinir ağı kullanılarak birer tahmin modeli geliştirilmiş ve bu iki modelin ürettiği sonuçlar karşılaştırılmıştır.

Modellerin eğitilmesi ve test edilmesi aşamasında kullanılmak üzere bir veri kümesi oluşturulmuştur. Veri kümesi oluşturulurken yangının etkime süresine bağlı olarak ortaya çıkan yüksek sıcaklık, ISO 834 (1975)'de verilen ve zamanın fonksiyonu olarak tanımlanan bağıntı ile hesaplanmaktadır. Sıcaklığın döşeme içerisindeki dağılımı, sürekli rejimde bir boyutlu ısı geçişi kabulü ile belirlenmektedir. Bu çalışmada, döşeme dilimlere ayrılmakta, yangının etkime süresine bağlı olarak dilimlerde oluşan sıcaklık belirlenmekte ve Eurocode 2 (1995)'de verilen azaltma katsayıları kullanılarak ortaya çıkan sıcaklık altındaki malzeme dayanımı ve kuvvetler hesaplanmaktadır. Kuvvetlerin dengesinden ise döşemenin eğilme kapasitesi elde edilmektedir. Farklı yangın etkime sürelerine maruz farklı özellikteki betonarme döşemelerin eğilme kapasiteleri değerlerinden bir veri kümesi elde edilmiştir. Veri kümesinin %55'i geliştirilen modellerin eğitim kümesinde, %45'i ise test kümesinde kullanılarak yapay ve bulanık sinir ağlarının, yangına maruz betonarme döşemelerin eğilme kapasitesini tahmin etme kabiliyeti araştırılmıştır. Ayrıca bu çalışmada, yüksek sıcaklığa maruz betonarme döşemelerin eğilme kapasitesinin modellenmesinde MATLAB (1999) paket programındaki ANN (Artificial Neural Networks) ve ANFIS araç kutusundaki araçlardan faydalanılmıştır.

3.1. Materyal

Yüksek sıcaklığa maruz betonarme döşemelerin eğilme kapasitelerinin tahmini için geliştirilen yapay ve bulanık sinir ağı modellerinde ağı eğitilmesi ve test edilmesi aşamalarında kullanılacak bir veri kümesine ihtiyaç vardır. Bu çalışmada,

farklı yangın etkime sürelerine maruz farklı özellikteki betonarme döşemelerin eğilme kapasiteleri hesaplanarak bir veri kümesi oluşturulmuştur. Farklı yangın etkime sürelerine maruz farklı özellikteki betonarme döşemelerin eğilme kapasitelerinin hesabında ISO 834 (1975) ve Eurocode 2 (1995)'deki bazı bağıntılardan yararlanılmıştır.

3.1.1. Yangına maruz betonarme döşemelerin taşıma gücü moment kapasiteleri

Yangına maruz kalan betonarme döşemelerin taşıma gücü moment kapasitelerini hesaplayabilmek için yangına maruz kalma süresine bağlı olarak ortaya çıkan yüksek sıcaklık, döşeme içindeki ısı dağılımı ve malzeme dayanımındaki azalma belirlenmelidir. Bunlar belirlendikten sonra, döşeme içindeki çekme ve basınç kuvvetleri incelenmektedir. Kuvvetler dengedeysen elde edilen moment, yangına maruz betonarme döşemenin taşıma gücü moment kapasitesini vermektedir.

3.1.2. Sıcaklık-zaman ilişkisi

Bu çalışmada, sıcaklık-zaman ilişkisini tanımlamak için ISO 834 (1975) kullanılmıştır. ISO 834 (1975)'de, sıcaklık-zaman eğrisi denklemi, denklem 3.1'deki ifade ile tanımlanmaktadır.

$$T = 345 \log_{10}(8t + 1) + T_a \quad (^\circ\text{C}) \quad (3.1)$$

Burada, t yangının dakika cinsinden etkime süresi, T_a ortamın $^\circ\text{C}$ cinsinden sıcaklığı, T ise yangının etkime süresine bağlı olarak ortaya çıkan $^\circ\text{C}$ cinsinden sıcaklıktır.

3.1.3. Yüksek ısı altında beton basınç dayanımı

Yüksek ısıya maruz betonun basınç dayanımında azalma meydana gelmektedir. Hesaplarda bu azalma göz önüne alınmalıdır. Betonun lokal basınç dayanımı σ_{CT} ,

her bir konumdaki sıcaklığı kullanılarak, Eurocode 2 (1995)'de verilen denklem 3.2'deki bağıntı ile hesaplanabilmektedir.

$$\frac{\sigma_{CT}}{\sigma_{C20^{\circ}C}} = k_c$$

$$\begin{aligned} k_c &= 1 && ; T \leq 100 \\ k_c &= 1.067 - 0.00067T && ; 100 \leq T \leq 400 \\ k_c &= 1.44 - 0.0016T && ; 400 \leq T \leq 900 \\ k_c &= 0 && ; T \geq 900 \end{aligned} \quad (3.2)$$

Burada, $\sigma_{C20^{\circ}C}$ ve σ_{CT} sırasıyla 20 °C'deki ve artan sıcaklıktaki beton basınç dayanımı, k_c basınç dayanımı azaltma katsayısı ve T ise sıcaklıktır.

3.1.4. Yüksek ısı altında çelik çekme dayanımı

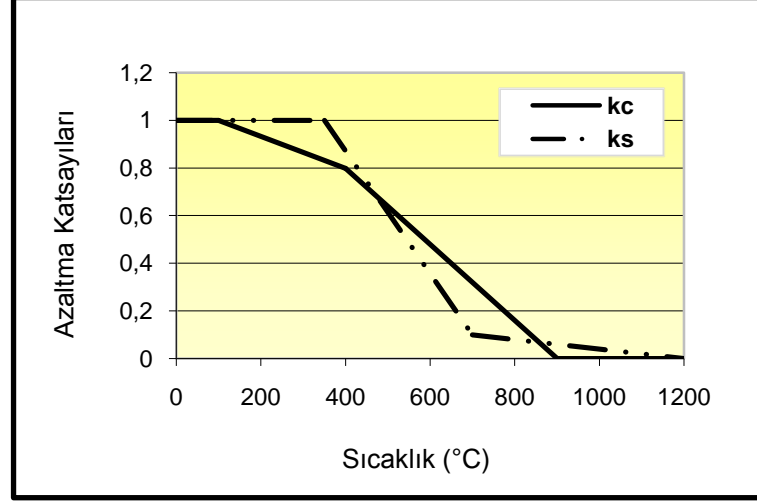
Sıcaklık nedeniyle donatının azalan çekme dayanımı değerlerinin belirlenmesinde, Eurocode 2 (1995)'de verilen denklem 3.3'deki bağıntıdan yararlanılmaktadır.

$$\frac{f_{suT}}{f_{su20^{\circ}C}} = k_s$$

$$\begin{aligned} k_s &= 1 && ; 0 \leq T \leq 350 \\ k_s &= 1.899 - 0.00257T && ; 350 \leq T \leq 700 \\ k_s &= 0.24 - 0.0002T && ; 700 \leq T \leq 1200 \\ k_s &= 0 && ; T \geq 1200 \end{aligned} \quad (3.3)$$

Burada, $f_{su20^{\circ}C}$ ve f_{suT} sırasıyla 20 °C'deki ve artan sıcaklıktaki çeliğin çekme dayanımını, k_s çelik çekme dayanımı azaltma katsayısını ifade etmektedir.

Eurocode 2 (1995)'de verilen beton ve çelik için dayanım azaltma katsayıları ile sıcaklık arasındaki ilişki Şekil 3.1'de grafiksel olarak gösterilmektedir.




Şekil 3.1. Beton ve çelik malzemesi için dayanım azaltma katsayıları (Erdem, 2008b; revize edilmiştir)

Şekil 3.1'den de görüldüğü gibi beton basınç dayanımı 100 °C'ye kadar değişmemekte, 400 °C'de normal sıcaklıktaki dayanımının % 20'sini, 700 °C'de dayanımının yaklaşık %70'ini, 900 °C'de ise dayanımının tamamını kaybetmektedir. Çelik çekme dayanımı 350 °C'den sonra azalmaya başlamakta, 400°C'de dayanımının %20'sini, 700 °C'de dayanımının %90'ını ve 1200 °C'de ise dayanımının tamamını yitirmektedir.

3.1.5. Plak döşemede sürekli rejimde ısı iletimi

Döşeme içindeki ısı iletimi sürekli ve bir boyutlu olarak modellenebilmektedir. Isı direnci kavramı, döşeme içinde sürekli rejimde ısı iletim oranını belirlemek için kullanılabilir. Şekil 3.2'de gösterildiği gibi, döşeme içerisinde sürekli ısı iletim oranı, toplam ısı direnci tarafından iki yüzeydeki bilinen sıcaklıklar kullanılarak denklem 3.4, 3.5 ve 3.6 ile ifade edilmektedir (Çengel, 1998; Genceli, 2000; Erdem, 2008b).



Şekil 3.2. Betonarme döşemede ısı iletimi

$$\frac{q}{A} = \frac{T_{\infty 1} - T_1}{\frac{1}{h_1}} = \frac{T_1 - T_2}{\frac{h}{k}} = \frac{T_2 - T_{\infty 2}}{\frac{1}{h_2}} \quad (3.4)$$

$$\begin{aligned} T_{\infty 1} - T_1 &= \frac{q}{A} \frac{1}{h_1} \\ T_1 - T_2 &= \frac{q}{A} \frac{h}{k} \\ T_2 - T_{\infty 2} &= \frac{q}{A} \frac{1}{h_2} \end{aligned} \quad (3.5)$$

$$Q = \frac{T_{\infty 1} - T_{\infty 2}}{R_t} \quad (3.6)$$

Burada, $T_{\infty 1}$ ve $T_{\infty 2}$ içinde ısı iletimi olmayan döşemenin iki yüzündeki sıcaklıklardır. R_t toplam ısı direnci de denklem 3.7'de verilen ifade ile elde edilir.

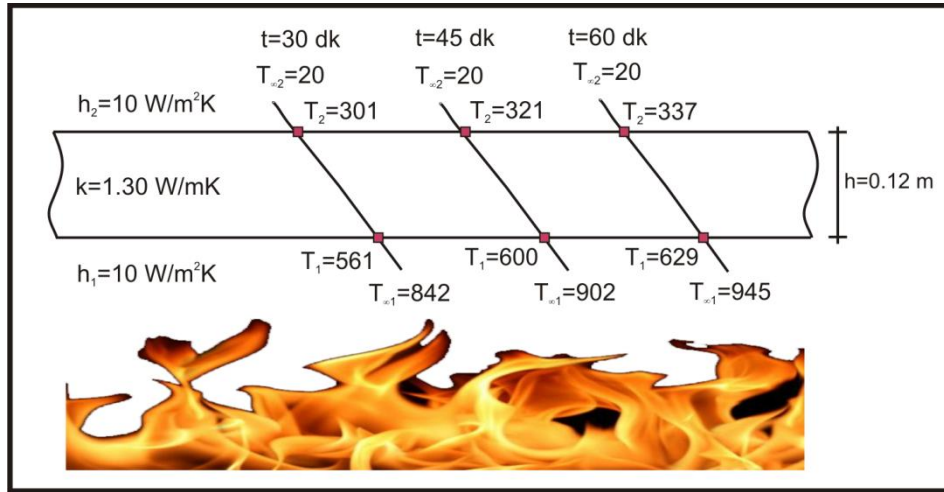
$$\begin{aligned} R_t &= R_1 + R_s + R_2 \\ R_t &= \frac{1}{h_1 A} + \frac{h}{k A} + \frac{1}{h_2 A} \end{aligned} \quad (3.7)$$

Burada, k betonun ısı iletim katsayısı, h_1 ve h_2 ısı taşınım katsayıları, A yüzey alanı ve h döşeme kalınlığıdır. Isı iletim oranı bilindiğinde T_1 ve T_2 hesaplanabilmektedir. Döşeme içinde herhangi bir dilimde y noktasındaki sıcaklık $T(y)$, denklem 3.8'deki bağıntı ile hesaplanabilmektedir.

$$T(y) = T_2 + (T_1 - T_2) \frac{y}{h} \quad (3.8)$$

Burada, T_1 yangına maruz kalan yüzeydeki sıcaklık, T_2 ise yangına maruz kalmayan diğer yüzeydeki sıcaklıktır.

Şekil 3.3'de özellikleri görülen betonarme döşemenin $t=30, 45$ ve 60 dakika yangına maruz kalması durumunda, döşemenin iki yüzünde meydana gelen sıcaklık değerleri örnek olması amacıyla hesaplanmıştır.




Şekil 3.3. Betonarme döşemede yangına maruz kalma süresine bağlı olarak oluşan sıcaklık dağılımı

3.1.6. Yüksek ısıya maruz betonarme döşemenin moment kapasitesi

Yüksek ısının malzeme özellikleri ve döşemenin moment kapasitesi üzerindeki etkilerinin incelenebilmesi için sıcaklık değişimlerinin bilinmesi gerekmektedir. Önceki bölümde verilen azaltma katsayılarından anlaşılacağı gibi, sıcaklık artışı malzeme özelliklerinin bozulması ve döşemenin moment kapasitesinin azalması ile

sonuçlanmaktadır. Döşeme içindeki malzeme özelliklerinin değişimini elde etmek için döşeme içerisindeki ısı dağılımının bilinmesi gerekmektedir. Bunun için betonarme döşeme en kesiti D kadar dilime bölünmekte ve her bir dilimin malzeme özellikleri, azaltma katsayıları ve mekanik özellikleri belirlenmektedir (Erdem, 2008b).



Şekil 3.4. Döşeme içerisindeki sıcaklık değişimi ve oluşan kuvvetler (Erdem, 2008b; revize edilmiştir)

Şekil 3.4'den görüldüğü gibi çelik donatılardaki çekme kuvveti denklem 3.9'da verilen ifade ile elde edilmektedir.

$$F_s = \sum_{i=1}^D k_{si} f_{yd} A_{si} \quad (3.9)$$

Betonun birim genişliği için basınç kuvveti, denklem 3.10'da verilen ifade ile basınç bölgesindeki basınç kuvvetlerinin toplamından elde edilebilmektedir.

$$F_c = 0.85 \sum_{i=1}^{\frac{a}{\Delta y}} k_{ci} f_{cd} \Delta y \quad (3.10)$$

En kesitteki kuvvetler dengede ise denklem 3.9 ve 3.10'un birbirine eşit olması gerekir. Eğer eşit değilse, a değeri dereceli olarak azaltılır ve hesap tekrarlanır. Bu işlem denklem 3.9 ve 3.10 birbirine eşit olana kadar devam ettirilir. Döşemedeki kuvvetler dengede olduğunda, döşemenin moment kapasitesi M_u denklem 3.11'de verilen ifade ile hesaplanabilmektedir (Erdem, 2008b).

$$M_u = 0.85 \sum_{i=1}^{\frac{a}{\Delta y}} k_{ci} f_{cd} \Delta y \left(d - \frac{\Delta y}{2} - i \Delta y \right) \quad (3.11)$$

Burada, f_{cd} betonun 20°C sıcaklığındaki basınç dayanımı, f_{yd} donatının 20°C sıcaklığındaki akma dayanımı, F_c ve F_s sırasıyla döşemedeki basınç ve çekme kuvvetleri, k_{ci} ve k_{si} ise döşemedeki her bir dilimin malzeme sıcaklığına karşılık gelen azaltma katsayılarıdır.

3.2. Yöntem

3.2.1. Yapay sinir ağları

İnsanın düşünme yeteneğini taklit etmeye yönelik olarak yapılan çalışmaların bir ürünü olan yapay zeka, aslında programlanmış bir bilgisayarın düşünme girişimidir. Yapay zeka kavramının temeli, ilk kez 1943 yılında II. Dünya savaşı sırasında Alan Mathison Turing tarafından “makinelere düşünebilir mi?” sorunun ortaya atılmasıyla doğmuştur. Yapay zeka kavramı fikrinin temelini atan her ne kadar Alan Mathison Turing olsa da, bu alanda yapılan çalışmalara ilk kez yapay zeka adını veren, Stanford Üniversitesinde Profesör olan John McCarthy olmuştur (www.tr.wikipedia.org/wiki/Yapay_zeka#Alt_dallar). McCarthy, ilk kez 1956’da ortaya attığı yapay zeka terimini “Makineleri zeki yapan mühendislik ve bilim dalı” şeklinde tanımlamıştır (Crevier, 1993). İnsan gibi düşünen ve davranan sistemlerin geliştirilmesi amacıyla yapılan yapay zeka çalışmaları 1950’li yıllardan beri sürmektedir.

Yapay zeka, insanın düşünerek çözüm üretme kabiliyetinin bilgisayar programlarına uyarlanmasına yönelik birden fazla sistemsel yaklaşımı gerektirmesinden ötürü çok sayıda alt dala ayrılmıştır. Bu alt dallardan en çok öne çıkanlar yapay sinir ağları, genetik algoritma, genetik programlama, bulanık mantık, uzman sistemler ve örüntü tanıma sistemleri olmuştur. Elbette bu örneklerin sayısını

arttırmak mümkündür çünkü yapay zeka çalışmaları çok geniş bir alanda yıllardan beri uygulanmaktadır.

Yapay zekanın bir alt dalı olarak ortaya çıkan YSA'lar, insan beyninin en küçük yapı taşı olan nöronu şekilsel ve işlevsel olarak basit bir şekilde taklit ederek biyolojik sinir sisteminin çalışma prensibine benzemeye çalışan bilgi işlem programlarıdır. Çok sayıda nöronun birbirine bağlanmasıyla oluşan biyolojik sinir sistemi ağının bir benzeşimi olan YSA'lar, insan beyninin düşünme, çıkarsama ve deneyerek öğrenmeye yönelik yeteneklerini kullanarak, bir bilgisayar sistemine girilen çok sayıda veriden öğrenme kapasitesi sağlamaktadır.


YSA'lar, insana özgü deneyerek öğrenme, yeni bilgiler türetebilme gibi yetenekleri kullanarak verileri işleyen bilgisayar sistemleridir (Öztemel, 2003). Geleneksel programlama yöntemleri ile verileri işleyerek öğrenme ve bu yol ile yeni bilgiler oluşturabilme yaklaşımını gerçekleştirmek mümkün değildir. YSA'ların, matematiksel olarak modellenmesi çok zor veya mümkün olmayan karmaşık olayların çözümlenmesine yönelik olarak geliştirilmiş adaptif bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olduğu söylenebilir (Öztemel, 2003).

YSA'ların özellikle mühendislik alanlarında yaygın bir biçimde kullanılmasının en önemli nedeni, geleneksel tekniklerle çözümü zor olan problemler için etkin bir alternatif çözüm oluşturmasıdır. Ayrıca, insanın beyinsel gücünü kullanarak yapması gereken matematiksel ve algoritmik hesaplama işlemlerini, geliştirilen bilgisayarlar sistemleri ile yapmak doğruluk açısından hata payını minimuma indirdiği gibi verileri hızlı bir şekilde işlemesi yönüyle zamandan da kazandırmaktadır.

YSA'lar, eğitim aşaması için kullanılan örnek verilere bakarak bilgiler toplamakta, genellemeler yapmakta ve daha sonra hiç görmediği örnekler ile karşılaşınca edindiği bilgileri kullanarak o örnekler hakkında karar verebilmektedir.

YSA'lar, insan beyninin işleyişinin bir benzeşimi olduğundan bu konu üzerindeki çalışmalar, ilk olarak beyin biyolojik sinir sistemini oluşturan nöronların

modellenmesi ve bilgisayar sistemlerinde uygulanması ile başlamıştır (Yurtoğlu, 2005). Şekil 3.5’de biyolojik bir nöronun genel yapısı görülmektedir.



Şekil 3.5. Biyolojik nöronun yapısı (<http://bilimge.com/index.php/component/content/article/68-yapay-sinir-aglari/830-yapay-sinir-aglari.html>)

Biyolojik bir nöronda 4 temel eleman vardır. Bunlar çekirdek (hücre gövdesi), akson, dendrit ve sinapstur. Dendrit, çekirdekten çıkan uzantılardır ve bir nöronun yüzlerce ya da binlerce dendrit çıkabilir. Dendritler, girdi kanalları olarak işlev görür ve diğer nöronların sinapsları aracılığıyla girdi sinyallerini alarak çekirdeğe iletir. Çekirdek gelen bu sinyalleri işler, çıktıya dönüştürür, daha sonra bu çıktıyı akson ve sinapslar aracılığıyla diğer nöronlara gönderir (Yurtoğlu, 2005).

YSA’lar biyolojik sinir sisteminin bir simülasyonu olduğundan aralarında yapısal olarak benzerlikler vardır. Bu benzerlikler Çizelge 3.1’de verilmiştir.

Çizelge 3.1. YSA ile sinir sistemi arasındaki yapısal benzerlikler

YSA	Sinir Sistemi
Nöron	İşlem Elemanı
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Akson	Eleman Çıkışı
Sinaps	Ağırlıklar

YSA'nın yapısını daha iyi anlayabilmek için öncelikle biyolojik sinir sisteminin yapısını anlamamız gerekir. Öğrenme dediğimiz kavram biyolojik sinir sistemindeki nöronları birbirine bağlayan sinaptik bağlantıların ayarlanması ile olur. Yaşayıp tecrübe ettikçe sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşur. Bu sayede öğrenme gerçekleşir. Bu durum YSA'lar için de geçerlidir. YSA'larda öğrenme, örnek veriler kullanılarak ağı eğitilmesiyle gerçekleşir. Diğer bir ifadeyle öğrenme, eğitim amacıyla kullanılan örnek girdi-çıkı verilerinin işlenmesi ve girdi-çıkı verileri arasındaki bağlantı ağırlıklarının bir yakınsama sağlanana kadar, tekrar tekrar ayarlanmasıyla olur (Öztemel, 2003).

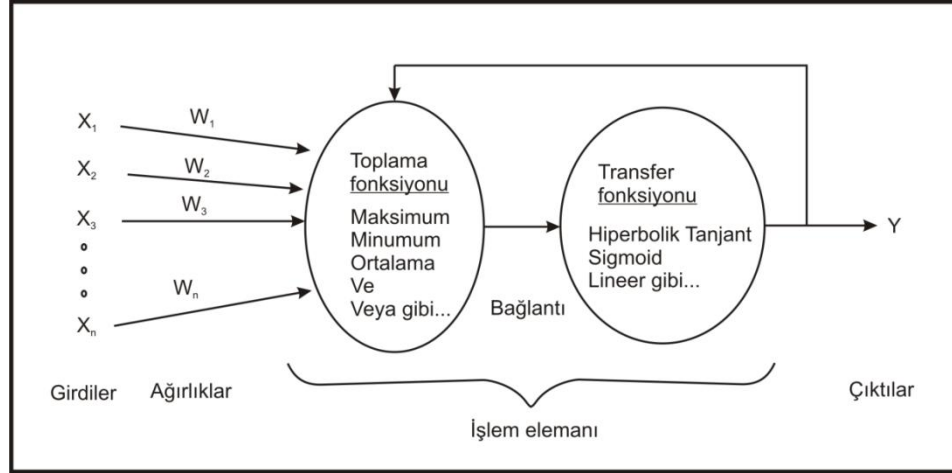
YSA dediğimiz sistem aslında, ağırlıklandırılmış şekilde birbirlerine bağlanmış nöron adı verilen çok sayıda işlem elemanlarından oluşan matematiksel sistemlerdir. İşlem elemanı, transfer fonksiyonu olarak anılan bir denklemdir. İşlem elemanı diğer nöronlardan gelen sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Bir ağ içindeki tüm işlem elemanları birbirlerine bağlanarak sinir ağını oluşturur.

YSA'ları geleneksel işlemcilerden ayıran özellik, sistemin çalışma yapısının dağıtılmış, adaptif ve doğrusal olmayan işlem elemanlarından oluşmasıdır. Geleneksel işlemcilerde tek bir merkezi işlem elemanı her hareketi sırasıyla gerçekleştirirken; YSA'larda çok sayıda işlem elemanından her biri, eş zamanlı olarak problemin bir parçası ile ilgilenir. Genel anlamda bir işlem elemanı girdi verisi aldığımda girdinin ağırlık bağlantısını belirleyerek ağırlıklandırır, algoritmaya göre doğrusal olmayan bir şekilde dönüşümünü sağlar ve bir çıktı oluşturur. İşlem elemanlarının ilk bakışta basit gibi görünen çalışma biçimi, ağı oluşturan çok sayıdaki işlem elemanlarının eş zamanlı olarak çalışması ve toplam işlem yükünü paylaşması ile güçlenir.

YSA'ların davranışı, girdi veriyi çıktı veriye nasıl ilişkilendirdiklerinden, nöronların birbirine bağlanma biçiminden, bu bağlantıların ağırlıklarından ve transfer fonksiyonlarından etkilenir.

YSA'lar yoğun bağlantılı ve karmaşık işlem yapıları nedeniyle, ancak özel yazılımlar ile bilgisayarlarda çalıştırılmaktadır (Yurtoğlu, 2005).


YSA'ları oluşturan yapay bir nöronun yapısı, genel olarak Şekil 3.6'da görülmektedir.



Şekil 3.6. Yapay nöronun yapısı (Yurtoğlu, 2005)

YSA'ları oluşturan yapay bir nöronda girilen veriler bağlantı ağırlıkları ile çarpılarak ağırlıklandırılır. Bir nöron aynı zamanda birden çok girdi verisi alır. Her girdinin kendine özgü bir bağlantı ağırlığı vardır. Bu ağırlıklar bağlantı gücünün bir ölçüsüdür. Bu bağlantılar eğitime algoritmalarına göre değişir. Veriler ağırlıklandırıldıktan sonra toplama fonksiyonuna gönderilir. Toplama fonksiyonu olarak birçok matematiksel algoritma kullanılabilir. Toplama fonksiyonuna gönderilen verilerin çıktı değerlerinin zamana bağlı olarak değişmesi istenen durumlarda toplama fonksiyonları, çıktıları transfer fonksiyonuna iletmeden önce üzerinde aktivasyon fonksiyonu olarak adlandırılan ilave işlemler yapar. Ancak aktivasyon fonksiyonu literatürü henüz tam olarak gelişmemiştir. Çoğu YSA'larda, üretilen çıktılar üzerinde herhangi bir etkisi bulunmayan birim aktivasyon fonksiyonu kullanılmaktadır. Aynı ağıdaki tüm işlem elemanlarının kullandığı aktivasyon fonksiyonu da aynıdır. Toplama fonksiyonunda üretilen çıktı bir sonraki aşama olarak transfer fonksiyonuna gönderilir. Transfer fonksiyonu genellikle doğrusal olmayan bir fonksiyondur. Çıktı ile girdinin orantılı olduğu doğrusal fonksiyonlar genelde tercih edilmez. Çünkü Minsky ve Papert (1969)'a göre, bu

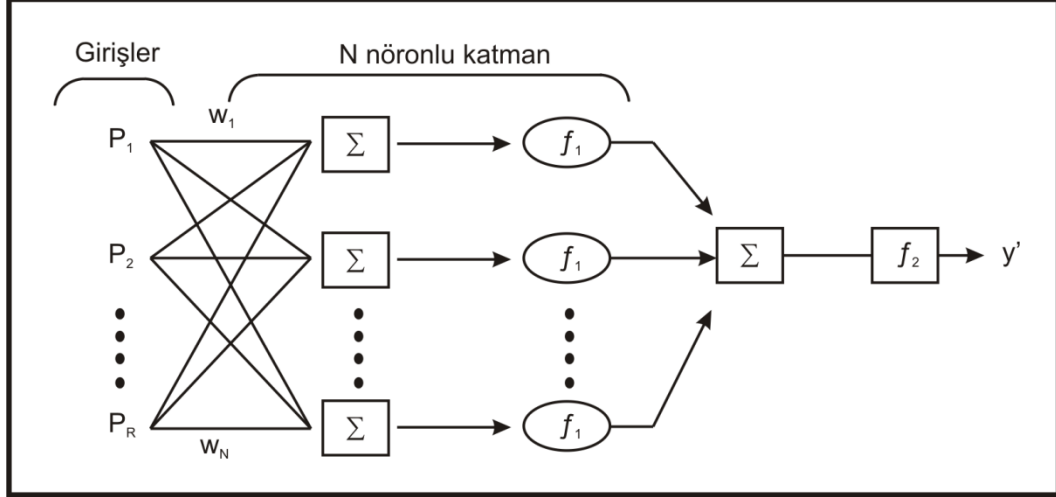
durum ilk YSA denemelerinin başarısızlıkla sonuçlanmasının temel nedenidir. Transfer fonksiyonunun veriyi işleyerek ürettiği çıktı işlem elemanın da çıktısıdır. Fakat bazen transfer fonksiyonundan çıkan değer bir çıktı fonksiyonu ile dönüştürülmesi gerekmektedir. Bu çıktı YSA'nın yapısına göre başka bir nörona ya da bir dış bağlantıya gönderilir (Yurtoğlu, 2005). Şekil 3.7'de en çok kullanılan transfer fonksiyonları görülmektedir.



Şekil 3.7. En çok kullanılan transfer fonksiyonları (Yurtoğlu, 2005)

Bir YSA modeli oluşturulurken genel olarak izlenen adımların başında ağız mimarisinin oluşturulması gelir. Ağız yapısı oluşturulduktan sonra uygun olan eğitim algoritması kullanılarak girdilerin ağırlık değerleri belirlenir. YSA, eğitim aşamasında girilen örnek verileri kullanarak ağırlıkları belirler, girdi değişkenleri ile tahmin edilen değişkenler arasındaki ilişkiyi ortaya çıkartır. Diğer bir deyişle eğitilir. Ağ eğitildikten sonra, YSA yeni verilerle çalıştırılabilir ve tahminler üretebilir. Bir ağız performansı, amaçlanan çıktı ve üretilen çıktı değerlerine bakılarak ölçülür. Ağız çıktısı, amaçlanan çıktı ile karşılaştırılarak hata payı elde edilir. Hata payını minimuma indirmek için geri yayılma algoritması kullanılarak bağlantı ağırlıkları tekrar ayarlanır. Bu işlem defalarca tekrar edilerek ağ eğitilir. (Yurtoğlu, 2005).

YSA'yı oluşturan sinir hücreleri farklı özellikte modellenebilmelerine karşın genel hatları ile çok girişli bir nöron örneği Şekil 3.8'de görülmektedir.



Şekil 3.8. Çok girişli N nöronlu hücre modeli (Çetin ve ark., 2006)

Şekil 3.8'de görülen hücre modelinde, P hücreye girilen veriler, w verilerin bağlantı ağırlıklarıdır ve ağırlık verinin hücre üzerindeki etkinliğini belirleyen bir faktördür. Σ toplama fonksiyonu ise ağırlıklandırılmış verilerin yani bağlantı ağırlığı ile giriş verilerinin çarpımının toplamıdır. Transfer fonksiyonu f ise toplama fonksiyonundan elde ettiği girdiyi bir işlemden geçirerek hücre çıktısını belirler. İşlem elemanı çıktısı, seçilen özel transfer fonksiyonuna bağlıdır. Sinir hücreleri, özellikleri bakımından Şekil 3.8'deki gibi olmakla birlikte işlevselliğine göre statik ya da dinamik hücre adını alırlar. Yukarıdaki şekilde görülen hücre modelinde ağırlıkların sabit olması ve geri besleme kullanılmaması hücreyi statik bir hücre yapar. (Çetin ve ark., 2006).

3.2.1.1. Yapay sinir ağlarının genel özellikleri

YSA, oluşturulan ağ yapısına bağlı olarak farklı karakteristik özelliklere sahip olmalarına karşın temelde birkaç ortak özellik gösterirler. Bu ortak özellikler şunlardır:

- Doğrusal olmama: YSA'nın en küçük bilgi işleme birimi olan hücrenin doğrusal olmaması, hücrelerden oluşan YSA'nın da lineer olmayan bir yapıya

sahip olmasını sağlar. Bu özelliği sayesinde YSA doğrusal olmayan karmaşık problemlerin çözümünde kullanılmaktadır.

- Genelleme: Eğitilmiş bir YSA, eğitim aşamasında elde ettiği girdi-çıkıtı verileri arasındaki ilişkiyi kullanarak daha önce karşılaşmadığı veriler için de uygun çıktılar üretebilir. Hatta YSA eksik veriyle karşılaştığı durumda dahi, eksik veriyi tamamlayarak en uygun çıktıyı üretme yeteneğine sahiptir (Efe ve Kaynak, 2004).

- Uyarlanabilirlik: YSA ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmekte eğitilmiş olan YSA, problemdeki değişimlere göre tekrar eğitilebilir (Efe ve Kaynak, 2004).

- Dağıtılmış birleşik hafıza: YSA’da nöral hesaplamalarda bilgiler ağdaki ağırlıklar üzerine dağıtılır. Bağlantıların ağırlıkları, nöral ağı hafıza birimidir. Bu ağırlıklar ağı o anda sahip olduğu bilgiyi verir.

- Paralel işlem yapma: YSA eş zamanlı çalışarak işlevleri yerine getiren birçok nörondan meydana gelir. YSA verileri işlerken bu nöronlardan biri herhangi bir nedenle işlevini yitirse dahi sistem bu durumdan etkilenmeyerek çalışmasına devam edebilir ve uygun sonuçlar üretebilir.

- Hata toleransı: YSA’yı oluşturan nöronlar arasındaki bağlantı paralel dağılmış bir yapıdadır ve bilgiler bağlantılarla ağa dağılmıştır. Giriş verilerinde bulunabilecek herhangi bir gürültü, ağırlıklar üzerine dağıtılması sayesinde tolere edilebilir. Geleneksel yöntemlerle karşılaştırıldığında, YSA’ların hatayı tolere etme yetenekleri daha fazladır (Efe ve Kaynak, 2004).

- Eksik bilgi ile çalışabilmektedirler: YSA’lar bir kez eğitildikten sonra veriler eksik olsa dahi, sistem bu durumdan etkilenmeden uygun çıktılar üretebilir. Geleneksel sistemlerde böyle bir durum söz konusu değildir.

3.2.1.2. Yapay sinir ağlarının dezavantajları

YSA'nın, avantajları olduğu kadar dezavantajları da vardır. Başlıca dezavantajları şunlardır:


- Donanım bağımlıdır: YSA'lar, özel yazılımlarla çalışan bilgisayar programları olduğundan donanıma bağımlı sistemlerdir. YSA'nın ortaya çıkmasındaki en önemli nedenlerinden biri olan paralel işlem yapabilme yeteneği, paralel çalışan işlemcilerle mümkün olmaktadır.
- Uygun ağ yapısının belirlenmesinde belli bir kural yoktur: YSA'nın en büyük sorunlarından biri uygun ağ yapısının belirlenmesidir. Çünkü ağın belirlenmesinde izlenecek bir yöntem yoktur. Uygun ağ yapısı çalışmalar sonucunda deneme yanılma yolu ile belirlenmektedir.
- Ağın parametre değerlerinin belirlenmesinde belli bir kural yoktur: YSA'da nöron sayısı, katman sayısı gibi parametrelerin belirlenmesinde belirli bir standart olmadığı gibi, her problem için farklı bir ağ tipi söz konusu olmaktadır.
- Öğrenilecek problemin ağa gösterimi önemli bir problemdir: YSA'lar bilgi işleme programları olduğundan sayısal bilgilerle çalışmaktadır. Bu nedenle problemin sayısal verilerden oluşan parametrelerle ortaya konması gerekmektedir. Bu da kullanıcının yeteneğine ve bilgi birikimine bağlıdır.
- Ağın eğitiminin ne zaman bitirilmesi gerektiğine ilişkin belli bir yöntem yoktur: YSA'da eğitim, gerçek çıktılarla üretilen çıktılar arasındaki hatanın belirli bir değerin altına inmesiyle tamamlanır. Henüz optimum neticeler veren bir mekanizma yoktur ve fakat bununla ilgili çalışmalar sürmektedir.

- Ağın davranışları açıklanamamaktadır: Bu sorun YSA'nın en önemli sorunudur. YSA bir probleme çözüm ürettiğinde, bu çözüme nasıl vardığına dair ipucu vermez. Sistemin, ürettiği sonuçlara nasıl ulaştığı bilinemez.

3.2.1.3. Yapay sinir ağlarının yapısı

Tek tabaka ya da tek eleman içeren bazı başarılı ağlar oluşturulmuşsa da birçok uygulamada başarılı çıktılardan üretilmesi için çok katmanlı ağlara ihtiyaç duyulmaktadır. Karmaşık problemlerde çok katmanlı ağ yapıları tek katmanlı ağlara göre daha güçlü çıktılar üretebilmektedir. Genellikle bir YSA modeli 3 katmandan (tabakadan) oluşur. Bu katmanlar girdi katmanı, gizli (saklı) katman ve çıktı katmanıdır. Girdi katmanı, dışarıdan girdileri alarak üzerinde herhangi bir işlem yapmadan girdileri bir sonraki katmana ileten tabakadır. Çıktı katmanı ise çıktılardan dışarıya iletildiği tabakadır. Girdi ve çıktı katmanı tek tabakadan oluşurken bu iki tabaka arasında yer alan gizli katman birden çok tabakadan oluşabilir. Gizli tabakalar çok sayıda nöron içerirler ve bu nöronlar ağdaki tüm nöronlarla bağlantılıdır.

Girdi ve çıktı tabakasında, çözülecek problemdeki girdi ve çıktı parametreleri sayısı kadar nöron bulunur. Oysa gizli tabakadaki nöron sayısının belirli bir sistemiği bulunmamaktadır (Uygunoğlu ve Yurtcu, 2006). Bu tabakadaki nöron sayısı deneme yanılma yolu ile belirlenir (Fauset, 1994). Şekil 3.9'da tipik bir üç tabakalı yapay sinir ağının yapısı görülmektedir.



Şekil 3.9. Genel bir YSA yapısı

Çoğu ağ türünde, gizli tabakada bulunan bir nöron sadece bir önceki tabakanın nöronlarından bilgi alır. Nöron bilgiyi işledikten sonra ise çıktısını bir sonraki tabakanın nöronlarına gönderir. Bu yapı, ağdaki bilginin iletilmesi bakımından bir ileri besleme ağı oluşturur. Diğer bir bağlantı şekli ise geri yayılmadır. Geri yayılma bağlantısı, herhangi bir katmandaki nöronun çıktısının kendinden önceki bir katmana gönderilmesidir (Yurtoğlu, 2005).

3.2.1.4. Yapay sinir ağlarının sınıflandırılması


Yıllardan beri süregelen yapay zeka çalışmalarının sonucunda, bugün 100'den fazla YSA modeli ve onlarca öğrenme algoritması vardır. Tüm bu modellere ve algoritmalara burada açıklık getirmek mümkün değildir. Bu nedenle ana hatlarıyla YSA'lar sınıflandırılarak genel bir bilgi verilecektir. YSA'larda işlemci elemanlar arasındaki bağlantıların yapısı, ağın yapısını belirler. Öğrenme algoritması istenilen hedef doğrultusunda bağlantıların nasıl değiştirileceğini belirler. Ağ belirli bir öğrenme kuralına göre, hatayı sıfıra indirgeyecek şekilde ağırlıkları değiştirir.

YSA'lar, yapılarına göre ileri beslemeli ve geri beslemeli ağlar olmak üzere ikiye; kullanılan öğrenme algoritmasına göre danışmanlı, danışmansız ve takviyeli öğrenme olmak üzere üçe; öğrenme zamanına göre de statik ve dinamik öğrenme olarak ikiye ayrılır.

İleri beslemeli ağlarda, herhangi bir katmandaki nöron sadece bir sonraki katmanın nöronlarına veri gönderir (Karlık, 2003). İleri beslemeli ağlarda giriş katmanından çıkış katmana doğru tek yönlü bilgi iletimi söz konusudur. Yani bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, aldığı bilgileri hiçbir değişikliğe uğratmadan gizli katmandaki hücrelere iletir. Ara katman ve çıkış katmanı ise bilgileri işleyerek ağın çıkışını belirler (Rojas, 1996). İleri beslemeli ağlar yapıları itibariyle doğrusal olmayan statik bir işlevi gerçekleştirir. İleri beslemeli ağlar genellikle geriye yayılım öğrenme algoritması ile birlikte kullanılmaktadır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı en çok tercih edilen öğretim algoritmasıdır. Bu

algoritma, hataları geriye doğru azaltmaya çalışmasından dolayı bu ismi almıştır. Bu ağlara geriye yayılım ağları da denmektedir. Çok katmanlı perseptron (Multi Layer Perseptron-MLP) ve LVQ (Learning Vector Quantization) ağları ileri beslemeli ağların en çok bilinen örnekleridir.

Geri beslemeli ağlarda ise, bir hücre kendinden önceki katmandaki en az bir hücreyi besler (Karlık, 2003). Geri beslemeli ağlarda hem ileri hem de geri yönde bilgi aktarımı söz konusudur. Bu yapıları geri beslemeli ağlara dinamik bir hafıza özelliği sağlar ve bir andaki çıkış o ana kadar olan tüm girişleri yansıtır (Sağiroğlu ve ark., 2003). Özellikle önceden tahmin uygulamalarında bu yapı kullanılır. Hopfield, Elman ve Jordan ağları bu ağlara örnek olarak verilebilir. Şekil 3.10'da ileri beslemeli ve geri beslemeli ağların bir örneği görülmektedir.



Şekil 3.10. İleri ve geri beslemeli ağ yapısı (Yurtoğlu, 2005)

Ağların eğitilmesi için danışmanlı (yönlendirmeli) öğrenme, danışmansız (yönlendirmesiz) öğrenme ve takviyeli öğrenme olarak 3 farklı yaklaşım vardır.

Danışmanlı öğrenme algoritmalarında, ağa eğitilmesi için örnek olarak verilen girdi değerlerinin karşılığında istenen çıkış değerleri de verilir. Ağ başlangıçta rastgele olarak belirlenen bağlantı ağırlıklarını kullanarak veriyi işler, çıktıyı üretir. İstenilen çıktı ile üretilen çıktı arasında fark varsa, sistem geriye dönerek uygun çıktıyı elde etmek için bağlantı ağırlıklarını tekrar günceller. İstenilen çıktı elde edilinceye kadar bağlantı ağırlıkları tekrar tekrar ayarlanır. Widrow-Hoff tarafından

geliştirilen delta kuralı, McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri besleme algoritması danışmanlı öğrenmeye örnek olarak verilebilir.

Danışmansız öğrenme algoritmalarında, ağ eğitilirken istenen çıkış değerlerine ihtiyaç olmaz. Ağa sadece girdi değerleri sağlanır. Sistem verileri işlerken izleyeceği yola kendi karar verir. Ağa başlangıçta bağlantı ağırlıkları için değerler verilir. Ayrıca girdi değerlerinin normalize edilmesi gerekir. Danışmansız öğrenme, bir diğer adıyla yönlendirmesiz eğitime, henüz tam olarak anlaşılammıştır. Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir.

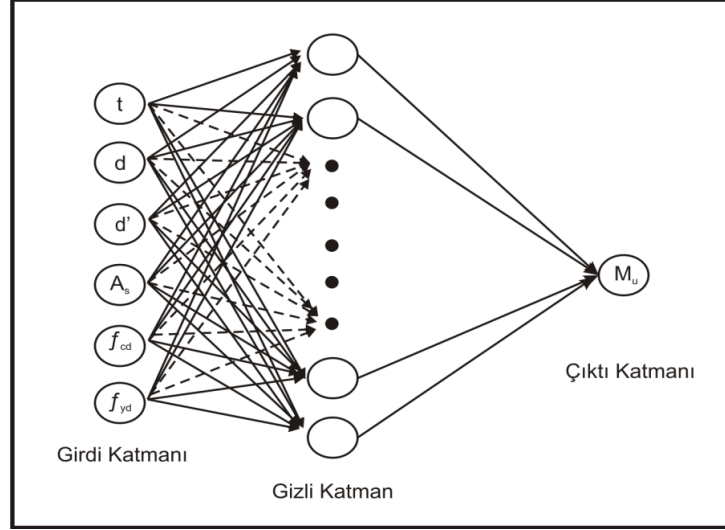
Takviyeli öğrenme kuralı danışmanlı öğrenmeye yakın bir metottur. Burada YSA'ya bir çıkış verilmemekte fakat elde edilen çıkışın verilen girişe karşılık iyiliğini değerlendiren bir kriter kullanılmaktadır. Öğrenme gerçek zamanda da devam etmekte ve ağ deneme-yanılma metoduna göre eğitilmektedir. Optimizasyon problemlerinde kullanılan Boltzmann kuralı veya Genetik Algoritmalar takviyeli öğrenmeye örnek olarak verilebilirler.

YSA, son olarak öğrenme zamanına göre 2'ye ayrılır. Statik öğrenmede, ağ eğitimini tamamlayıp bağlantı ağırlıklarını belirledikten sonra kullanılır. Eğitim tamamlandıktan sonra bağlantı ağırlıkları değişmez. Dinamik öğrenmede ise, ağ eğitimini tamamladıktan sonra da öğrenmeye ve bağlantı ağırlıklarını ayarlamaya devam eder.

3.2.1.5. Uygulanan YSA modeli

Bu araştırma için geliştirilen YSA modelinde, girdi katmanında 6 nöron, gizli katmanda 15 nöron ve çıktı katmanında 1 nöron bulunmaktadır. Giriş parametreleri şunlardır: Döşemenin çekme bölgesindeki donatının merkezinden beton dış kenar lifine olan uzaklığı yani pas payı (d'), faydalı yükseklik (d), çekme bölgesine yerleştirilen donatının alanı (A_s), yangına maruz kalma süresi (t), betonun basınç

dayanımı (f_{cd}) ve donatının akma dayanımı (f_{yd}). Bu çalışmada, LM sinir ağı eğitim algoritması olarak seçilmiştir. Kullanılan yapay nöronun mimarisi Şekil 3.11’de gösterilmiştir.



Şekil 3.11. Geliştirilen YSA mimarisi

Betonarme bir döşemenin taşıma gücü moment kapasitesinin YSA ile tahmini için veriler önceki bölümde verilen metotlar kullanılarak elde edilmiştir. Verilerin elde edilmesi sürecinde $k=1.30$ W/mK ve $h_1=h_2=10$ W/m²K değerleri sabit olarak alınmıştır. Geliştirilen modelde kullanılan girdi katmanındaki parametreler şunlardır;

- d' (10, 20, 30, 40 mm),
- d (100, 110, 120, 130 mm),
- A_s (679, 924 ve 1206 mm²),
- t (0, 3, 5, 7, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55, 60, 65, 70, 75, 80, 85, 90, 95, 100, 105, 110, 115, 120, 125, 130, 135, 140, 145, 150, 155, 160, 165, 170, 175, 180 ve 185 dk),
- f_{cd} (20, 25, 30 ve 35 N/mm²) ve
- f_{yd} (220 ve 420 N/mm²).

Bu çalışmada, YSA modeli MATLAB (1999) programı kullanılarak geliştirilmiştir. Bu analizde 520 veri kullanılmıştır ve bu verilerin %55'i modeli eğitmek, %45'i ise test etmek için kullanılmıştır. Veriler, parametrelerin maksimum

değerleri kullanılarak normalize edilmiştir. Ağı eğitmek için eğitim örneği ağa rastgele olarak girilmiş ve moment kapasitesi değerlerini tahmin edebilmek için YSA modeli uygulanmıştır.

3.2.2. Bulanık sinir ağları

Bulanık sistemler, giriş değişkenlerini bulanık kümeleri kullanarak çıkış değişkenlerine dönüştüren sistemlerdir (Zadeh, 1965).

Bulanık sistemler, sinirsel ağlarla bulanık fikirlerin birleşmesi sonucu oluşan sistemlerdir. Bu sistemler, modellemelerde sözel verilere yer vermesi bakımından önemlidir. Sözel verilerin modele dahil edilebilmesi için modelin değişkenleri bulanık alt kümelerle ifade edilir. Bir çıkarıma varılabilmesi için klasik küme işlemleri genelleştirilerek bulanık küme işlemleri yapılır. Bulanık çıkarım sistemleri, sayısal ve sözel verilerin birleştirildiği, “eğer-ise” kuralları adı verilen bulanık kurallara dayanan sistemlerdir. Bu nedenle bulanık çıkarım sistemleri, bulanık kural tabanlı sistemler olarak da adlandırılır. Bazı kaynaklarda bulanık çıkarım sistemleri, bulanık model, bulanık çağrışımlı bellek, bulanık mantık kontrolör olarak da adlandırılmaktadır (Jang, 1997; Özgan ve ark., 2009).

Temeli bulanık “eğer-ise” kurallarına dayanan bulanık çıkarım sistemleri öncül ve soncul kısımlardan oluşmaktadır. Öncül kısımda sonuca neden olan giriş değişkenleri ve bunlar arasındaki mantıksal ilişkiler, soncul kısımda ise bu giriş değişkenlerine bağlı olarak ortaya çıkan sonuç değişkenleri yer alır. Genel formuyla bir bulanık kural aşağıdaki gibidir (Özgan ve ark., 2009):

Kural: eğer A (“koşul”) ise B (“sonuç”)

Burada A öncül kısımdaki girdi değişkenlerince belirlenen şartları, soncul kısımdaki B ise çıktı değişkenini temsil etmektedir.

Sinirsel-bulanık sistem birleşimi yıllardır kontrol, veri analizi, karar destek gibi çeşitli amaçlarla kullanılmaktadır. Sinirsel-bulanık sistem sayesinde bulanık sınıflayıcıların veriden öğrenmesi basit bir şekilde sağlanmaktadır. Sinirsel-bulanık sistemleri diğer sistemlerden ayıran özellikleri şu şekilde sıralayabiliriz (Uygunoğlu ve Yurtcu, 2006):

- Sinirsel-bulanık sistem, öğrenme algoritması için sinir ağı teorisi kullanılarak eğitilen bir bulanık sistemdir.
- Bir sinirsel-bulanık sistem, 3 katmanlı ileri beslemeli özel bir sinir ağı olarak görülebilir. Bu ağın katmanları, sinir ağındaki aktivasyon potansiyeli yerine t-norms veya t-conorms kullanırlar. İlk katman giriş değişkenlerinden, orta katman bulanık kurallardan ve üçüncü katman ise çıkış değişkenlerinden oluşur.
- Bir sinirsel-bulanık sistem genellikle bir bulanık kurallar sistemi gibi düşünülür.
- Bir sinirsel-bulanık sistem, eğitim verisi ile verilen n boyutlu bir fonksiyon çıkarımı yapar. Ayrıca sinirsel-bulanık sistemi, bir bulanık uzman sistemi gibi görülmemeli; verilerden bir bulanık sistem oluşturma tekniği veya örneklerden öğrenerek bunu geliştiren bir teknik olarak düşünülmelidir.

Bulanık mantık ve sinir ağları, birbirlerinin eksik taraflarını tamamlayan ve akıllı sistemlerin geliştirilmesinde birlikte kullanılan tamamlayıcı araçlardır. Yapay sinir ağları, ham verilerle uğraşan düşük seviyeli yapılardır. Bulanık mantık ise, dilsel bilgileri kullanarak daha yüksek seviyeli sonuçlar çıkaran yapılardır. Aslında bulanık sistemler, sinir ağlarının öğrenme kabiliyetinden ve çevreye adapte olma özelliklerinden yoksundur. Diğer yandan yapay sinir ağları öğrenme kabiliyetine sahiptir fakat kullanıcı tarafından anlaşılabilir (Narendra ve Parthasarathy, 1990; Jang ve ark., 1997).

Sinirsel bulanık sistemler, yapay sinir ağlarının öğrenme kabiliyeti ve paralel işlem yapma gücü ile bulanık mantığın çıkarsama yapabilme özelliklerinin birleşiminden oluşur. Sonuç olarak sinirsel bulanık sistemler sayesinde yapay sinir ağları daha anlaşılır hale gelir (Jang, 1993).

Uygulamada bulanık çıkarım sistemleri için çok sayıda ve değişik modeller önerilmektedir (Jang ve ark., 1997). Bu çıkarım sistemleri genel işlem sırası ve uygulaması bakımından birbirine benzemekle birlikte soncul kısımlardaki üyelik fonksiyonlarının yapıları itibariyle farklılık gösterirler. Bulanık çıkarım sistemleri soncul kısımlardaki bu farklılıklar bakımından üç farklı gruba ayrılmaktadır. Bunlar Mamdani, Tsukamoto ve Sugeno tipi çıkarım sistemleridir. Bunlardan Sugeno tipi çıkarım sistemi, parametrelerinin kolay bir şekilde optimize edilebilmesini sağlaması bakımından diğer sistemlerden daha avantajlıdır (Özgan ve ark., 2009).

Sugeno tipi bulanık çıkarım sistemlerinde çıktı değişkenin üyelik fonksiyonu, girdi değişkenlerinin lineer bir fonksiyonu ya da sabit bir fonksiyon şeklindedir. Parametreleri optimize edilen Sugeno tipi bulanık çıkarım sistemlerine ANFIS denir (Jang, 1997).

ANFIS parametrelerinin optimizasyonunda, geriye yayma, en küçük kareler kestirimi, Kalman filtresi ya da birden fazla matematiksel optimizasyon yönteminin birleşmesinden oluşan hybrid öğrenme algoritmaları gibi değişik yöntemler kullanılabilir (Akyılmaz ve ark., 2003).

3.2.2.1. ANFIS mimarisi


Esasen ANFIS yapısı, Sugeno tipi bulanık sistemlerin, sinirsel öğrenme kabiliyetine sahip bir ağ yapısı olmasından ibarettir. Bu ağ, gerçekleştirdikleri fonksiyona göre katmanlar halinde gruplanmış düğümlerin birleşiminden oluşmuştur. Her bir düğüm belli bir görevi yerine getirir (Tsoukalas ve Uhrig, 1996).

ANFIS'in yapısına geçmeden önce Sugeno tipi bulanık sistemlerden bahsedelim. Basit olması açısından, bulanık çıkarım sisteminin, x ve y gibi iki girişi ve z gibi bir çıkışı olduğunu varsayalım. İki tane bulanık “eğer-o halde” kuralı bulunan, birinci dereceden Sugeno bulanık modeli için tipik kural kümesi;

Kural-1: Eğer x A₁ ise ve y B₁ ise o halde f₁ = p₁ x + q₁ y + r₁

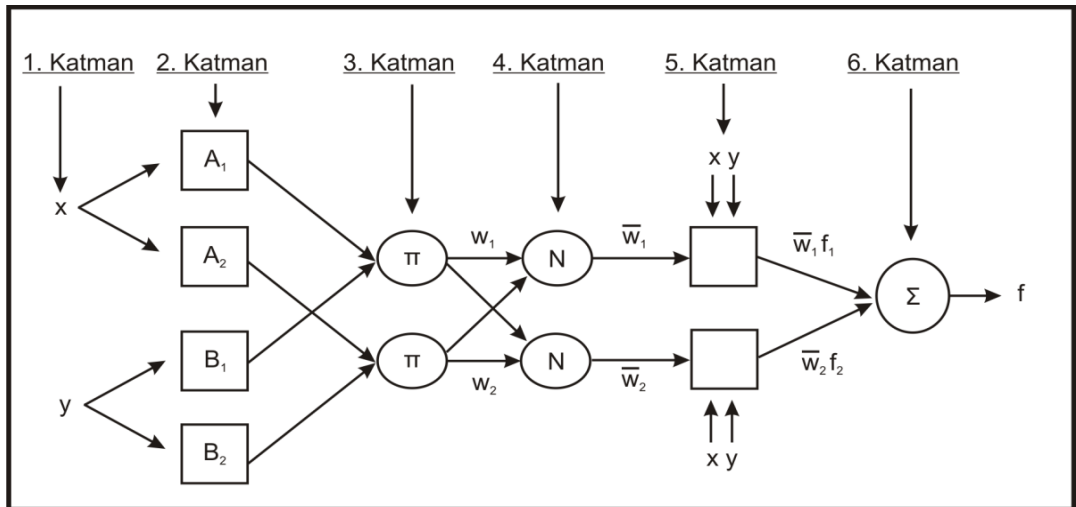
Kural-2: Eğer x A₂ ise ve y B₂ ise o halde f₂ = p₂ x + q₂ y + r₂

şeklinde ifade edilir. Şekil 3.12, bu Sugeno bulanık modeli için bulanık akıl yürütme mekanizmasını göstermektedir (Özçalık ve Uygur, 2003).



Şekil 3.12. Sugeno bulanık modeli için bulanık çıkarım sistemi (Özçalık ve Uygur, 2003)

Bu yapıya karşılık gelen, eşdeğer ANFIS mimarisi Şekil 3.13'de gösterilmiştir.



Şekil 3.13. ANFIS mimarisi (Özçalık ve Uygur, 2003)

ANFIS'te aynı katmanda bulunan düğümler, aynı düğüm fonksiyonlarına sahiptirler (Özçalık ve Uygur, 2003). Şekil 3.13'den de görüldüğü gibi ANFIS 6 katmandan oluşmaktadır. Bazı uzmanlar giriş katmanını saymayarak ANFIS'in 5 katmandan oluştuğunu kabul ederler. ANFIS yapısında her katmandaki düğümlerin işlevleri ve katmanların işleyişi sırasıyla şöyledir (Jang, 1993; Hocaoğlu ve Kurban, 2005):

1.Katman: Giriş katmanıdır. Bu katmandaki her düğümden alınan giriş sinyalleri diğer katmanlara aktarır.

2.Katman: Bulanıklaştırma katmanıdır. Bu katmandaki her düğüm üyelik derecesini belirleyen bir fonksiyona sahiptir. Bu üyelik dereceleri aynı zamanda katmanların çıkışıdır. Buradaki en önemli husus kullanılan fonksiyonların türevlerinin mevcut olması gerektiğidir. Bu katmandan elde edilen üyelik dereceleri $\mu_{A_i}(x)$ ve $\mu_{B_i}(y)$ şeklinde gösterilir. Burada n. katmandaki i. düğümün çıkışını $O_{n,i}$ şeklinde belirtirsek bu katmandaki her bir düğümünün çıkışı, denklem 3.12 şeklindedir.

$$\begin{aligned} O_{2,i} &= \mu_{A_i}(x) \\ O_{2,i} &= \mu_{B_i}(y) \end{aligned} \quad (3.12)$$

3.Katman: Kural katmanıdır. Bu katmanda düğüme gelen işaretlerin çarpımı anlamına gelen T-norm işlemi gerçekleştirilir. Bu katmandaki her bir düğüm, kendisine gelen sinyallerin çarpımını çıkış olarak üreten, Π ile etiketlenmiş sabit bir düğümdür. Her bir düğümün çıkışı denklem 3.13 şeklindedir ve her bir kural için ateşlenme seviyesini (gerçekleme derecesini) oluşturur.

$$O_{3,i} = w_i = \mu_{A_i}(x) \mu_{B_i}(y) \quad (3.13)$$

Denklem 3.13'deki bağıntıda çarpma işlemi yerine bulanık "ve" işlemini icra eden, başka T-norm işlemleri de düğüm fonksiyonu gibi kullanılabilirler.

4.Katman: Normalizasyon katmanıdır. 4.katmandaki düğümler, N ile etiketlenmiş sabit düğümlerdir. Bu katmandaki her bir düğüm, kural katmanından gelen çıkışları giriş değeri olarak kabul eder ve her bir kuralın normalleştirilmiş ateşleme seviyesini hesaplar. Katmandaki i. düğüm, i. kuralın gerçekleştirme derecesinin, bütün kuralların gerçekleştirme dereceleri toplamına oranını hesaplar (Denklem 3.14).

$$O_{4,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (3.14)$$

Bu katmanda yer alan düğümlerin çıkışları, normalize edilmiş ateşleme seviyeleri (gerçekleştirme dereceleri) olarak adlandırılırlar.

5.Katman: Arındırma katmanıdır. Arındırma katmanında, verilen bir kuralın ağırlıklandırılmış sonuç değerleri her bir düğüm için hesaplanır. 5. katmandaki i. düğümün çıkış değeri denklem 3.15'te görülmektedir.

$$O_{5,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (3.15)$$

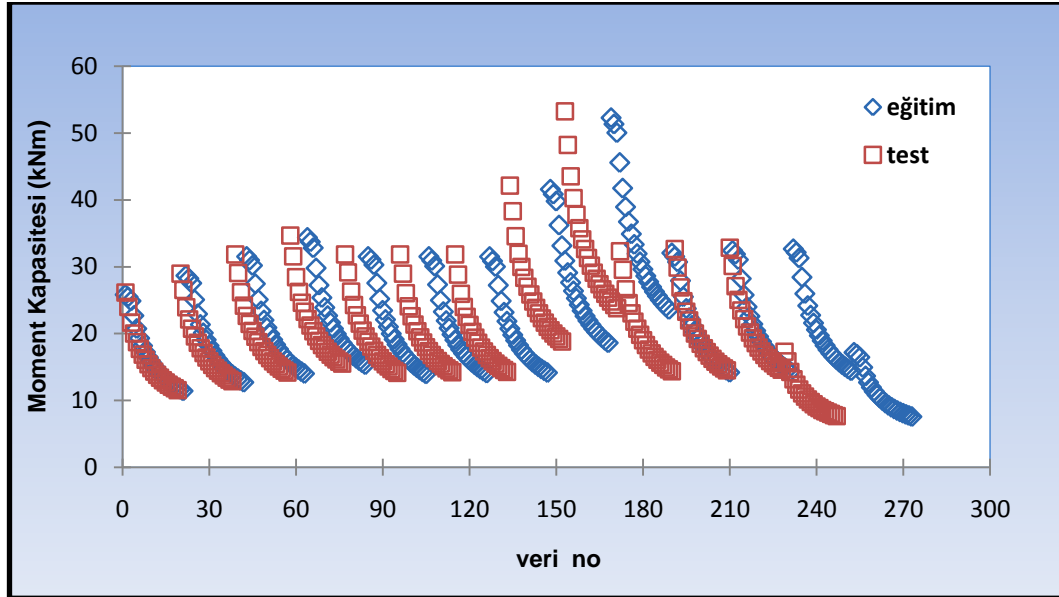
Burada \bar{w}_i , 4.katman'ın çıkışı olup, p_i, q_i, r_i ise bu katmanda bulunan düğümlerin parametrelerinden oluşan, parametre kümesidir.

6.Katman: Toplam katmanıdır. Son katmandır. Bu katmanda sadece bir düğüm vardır ve adına uygun olarak Σ ile etiketlenmiştir. Burada, 5. katmandaki her bir düğümün çıkış değeri toplanarak sonuçta, ANFIS sisteminin gerçek değeri elde edilir (Denklem 3.16).

$$O_{6,i} = \Sigma \bar{w}_i f_i = \frac{\Sigma w_i f_i}{\Sigma w_i} \quad (3.16)$$

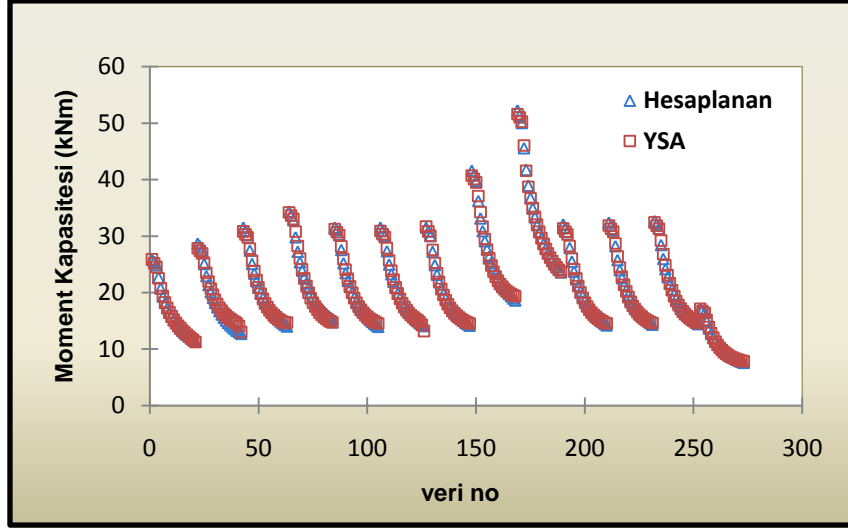
4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Bu çalışmada, yangına maruz betonarme döşemelerin moment kapasitelerinin tahmini için 520 adet veri kullanılarak bir YSA ve ANFIS modeli geliştirilmiş ve elde edilen sonuçlar karşılaştırılmıştır. YSA ve ANFIS modelleri için kullanılan eğitim ve test verileri Şekil 4.1’de verilmektedir.

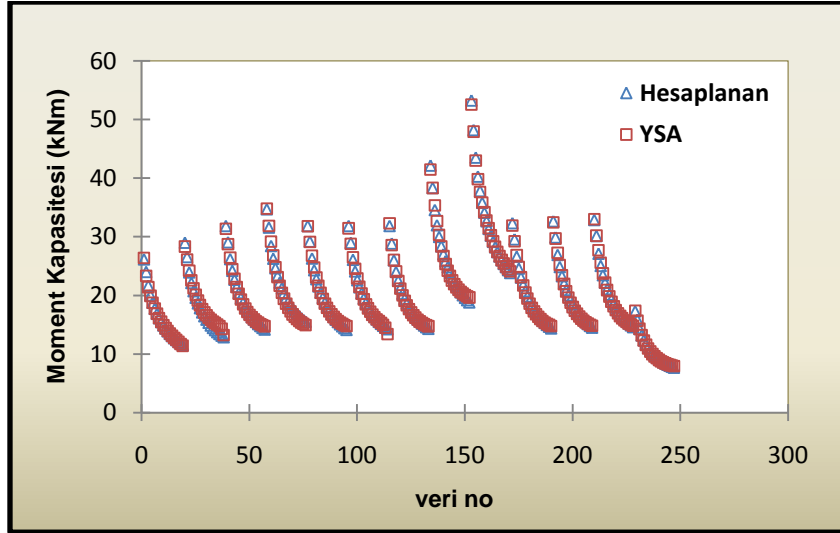


Şekil 4.1. Moment kapasitesinin tahmini için kullanılan eğitim ve test verileri

Yüksek ısıya maruz betonarme döşemenin moment kapasitesinin YSA metoduyla tahmini için geliştirilen programın kullanılmasıyla elde edilen ve hesaplanan moment kapasitesi arasındaki ilişki, eğitim ve test aşaması için sırasıyla Şekil 4.2 ve Şekil 4.3’de görülmektedir.




Şekil 4.2. Hesaplanan ve YSA modeli ile tahmin edilen moment kapasite değerleri (Eğitim aşaması için)

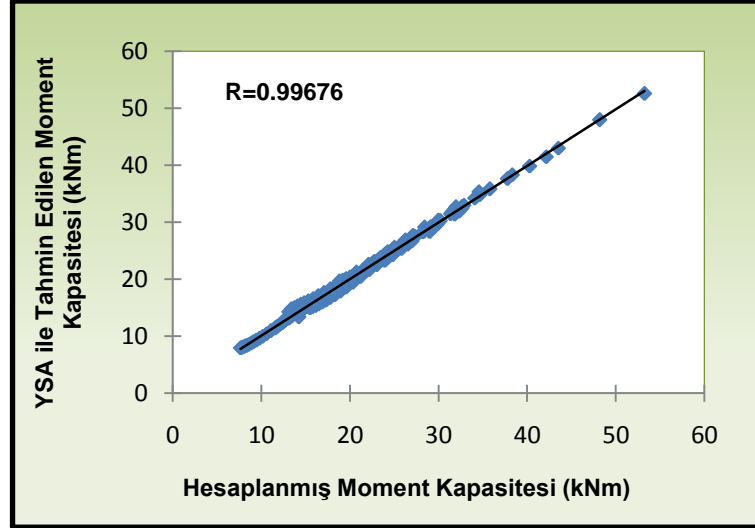


Şekil 4.3. Hesaplanan ve YSA modeli ile tahmin edilen moment kapasite değerleri (Test aşaması için)

Bu çalışmada geliştirilen YSA modeli, eğitim aşamasını 0.99678; test aşamasını ise 0.99676 korelasyon katsayısı ile tamamlamıştır. Eğitim ve test aşamalarını yüksek bir korelasyon katsayısı ile tamamlaması önerilen modelin, moment kapasitesini belirlemek için oldukça uygun olduğunu göstermektedir. Şekil 4.4 ve Şekil 4.5'de sırasıyla eğitim ve test aşamasında hesaplanmış olan moment kapasitelerine karşı YSA modeliyle tahmin edilen moment kapasitesi değerleri görülmektedir.

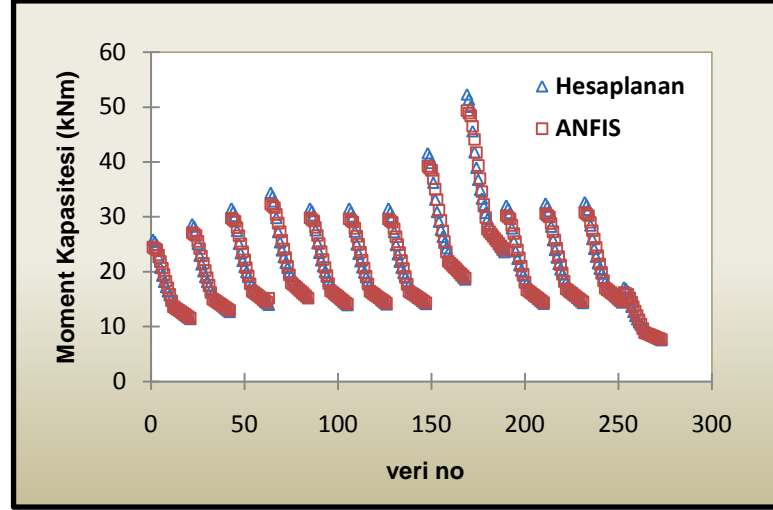


Şekil 4.4. Hesaplanan ve YSA modeli ile tahmin edilen moment kapasitelerinin karşılaştırılması (Eğitim aşaması için)

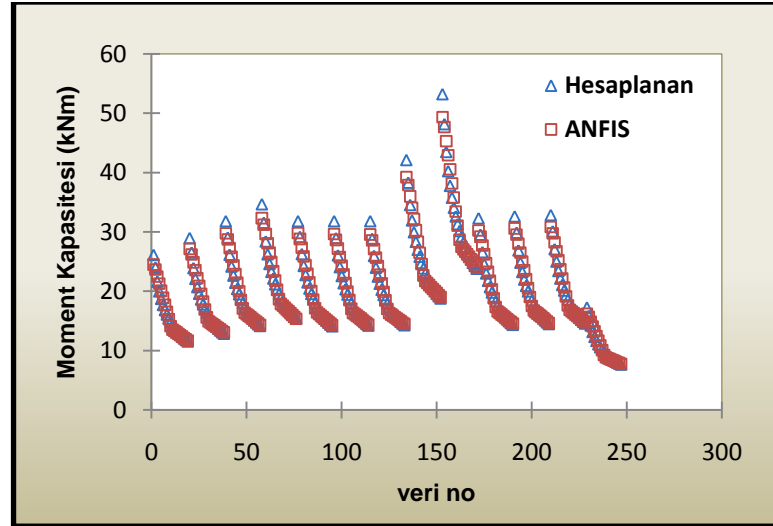


Şekil 4.5. Hesaplanan ve YSA modeli ile tahmin edilen moment kapasitelerinin karşılaştırılması (Test aşaması için)

Hesaplanan moment kapasitesi değerlerine karşılık ANFIS modeliyle elde edilen moment kapasitesi değerleri arasındaki ilişki ise eğitim ve test dataları için sırasıyla Şekil 4.6 ve Şekil 4.7’de görülmektedir.




Şekil 4.6. Hesaplanan ve ANFIS modeli ile tahmin edilen moment kapasite değerleri (Eğitim aşaması için)

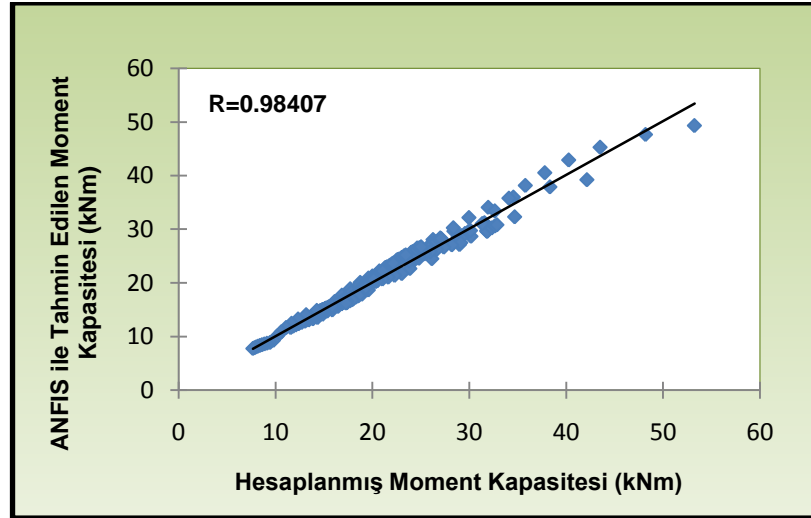


Şekil 4.7. Hesaplanan ve ANFIS modeli ile tahmin edilen moment kapasite değerleri (Test aşaması için)

ANFIS modelinde eğitim aşamasında korelasyon katsayısı 0.98250, test aşamasında ise 0.98407 olarak elde edilmiştir. Elde edilen bu değerler ANFIS modelinin moment kapasitesini belirleme kabiliyetini ortaya koymaktadır. ANFIS'in eğitim ve test aşamasında, hesaplanmış olan moment kapasitelerine karşın elde ettiği moment kapasiteleri grafiksel olarak sırasıyla Şekil 4.8 ve Şekil 4.9'da görülmektedir.

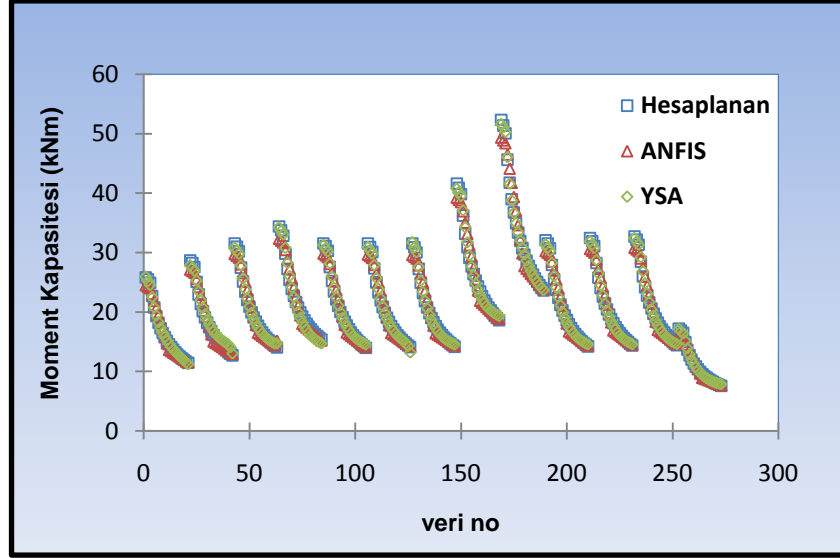


Şekil 4.8. Hesaplanan ve ANFIS modeli ile tahmin edilen moment kapasitelerinin karşılaştırılması (Eğitim aşaması için)

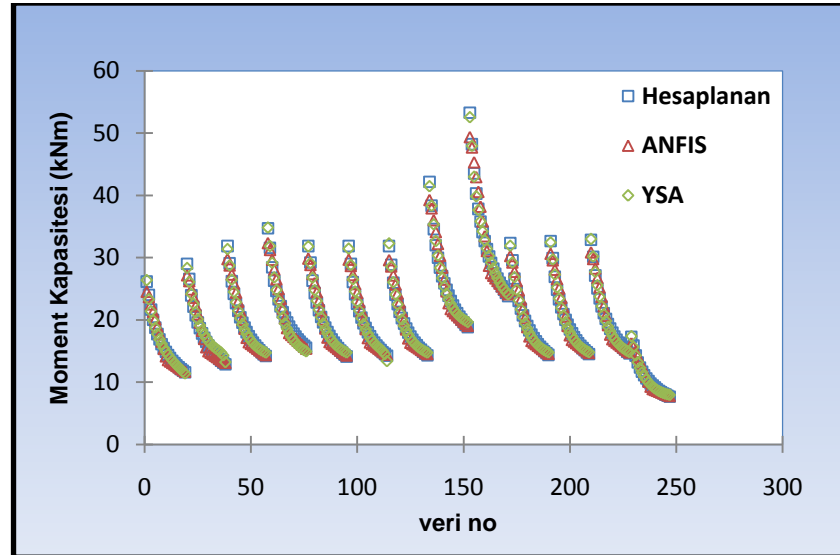


Şekil 4.9. Hesaplanan ve ANFIS modeli ile tahmin edilen moment kapasitelerinin karşılaştırılması (Test aşaması için)

YSA modelinin moment kapasitelerini, ANFIS modelinden daha iyi tahmin edebildiği görülmektedir. Şekil 4.10 ve Şekil 4.11’de, hesaplanan moment değerlerine karşılık YSA ve ANFIS modeliyle elde edilen moment taşıma gücü arasında bir karşılaştırma hem eğitim aşaması, hem de test aşaması için görülmektedir. Grafikler incelendiğinde ve elde edilen sonuçlar irdelendiğinde, yüksek ısıya maruz betonarme bir döşemenin moment kapasitesindeki değişimi YSA modelinin, ANFIS modelinden daha iyi tahmin edebildiği sonucuna varılmaktadır.



Şekil 4.10. Hesaplanan moment değerlerinin eğitim aşamasında tahmin edilen moment değerleriyle karşılaştırılması



Şekil 4.11. Hesaplanan moment değerlerinin test aşamasında tahmin edilen moment değerleriyle karşılaştırılması

Bu tez çalışmasında elde edilen sonuçlar, grafiksel olarak gösterilmiştir. Ayrıca, sonuçlar global istatistiksel parametreler ile birbirleriyle kıyaslanmıştır. Bu istatistiksel parametreler sırasıyla korelasyon katsayısı (correlation coefficient, R), karesel hataların ortalama karekökü (Root Mean Square Error, RMSE) ve ortalama taraflı hata (Mean Bias Error, MBE) olarak belirlenmiştir. R, hesaplanan ve tahmin edilen değerler arasındaki lineer ilişkiyi görebilmek için kullanılır ve ideal değeri 1'dir. RMSE, kısa süreli performans (short term performance) hakkında bilgi verir. RMSE'nin değeri daima pozitifdir ve ideal değeri 0'dır. MBE, hesaplanan ve tahmin

edilen her bir terim arasındaki gerçek sapmanın kıyaslanmasına izin vermek suretiyle korelasyonların uzun süreli performansı (long term performance) hakkında bilgi verir. MBE'nin ideal değeri 0'dır. Bu parametreler formülasyon olarak sırasıyla denklem 5.1, 5.2 ve 5.3'de verilmektedir.

$$R = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - O_{ort.})^2} \quad (5.1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (P_i - O_i)^2}{N}} \quad (5.2)$$

$$MBE = \frac{\sum_{i=1}^N (P_i - O_i)}{N} \quad (5.3)$$

Elde edilen istatistiksel sonuçlar Çizelge 5.1'de hem eğitim hem de test evresi dikkate alınarak tablo halinde verilmiştir.

Çizelge 5.1. Elde edilen global istatistiksel değerler

	Global İstatistiksel Değerler	Eğitim Evresi	Test Evresi
ANFIS için	R	0.98250	0.98407
	RMSE	1.02908	1.01951
	MBE	-0.00001	0.09552
YSA için	R	0.99678	0.99676
	RMSE	0.44119	0.40896
	MBE	-0.00215	0.00314


Bu çalışma sonucunda, yüksek ısıya maruz betonarme döşemelerin eğilme kapasitesinin belirlenmesinde YSA ve ANFIS yaklaşımının çok uygun sonuçlar ürettiği; YSA yaklaşımının ANFIS modeline göre çok daha uygun sonuçlar ürettiği görülmüştür.

5. SONUÇLAR ve ÖNERİLER

5.1. Sonuçlar

5.1.1. Döşemenin faydalı yüksekliğinin moment kapasitesi üzerindeki etkisi

Çalışmanın bu kısmında, yüksek ısıya maruz kalan döşemenin, farklı döşeme faydalı yükseklikleri için taşıma gücü moment kapasiteleri YSA ve BSA metodu kullanılarak incelenmiştir. Hesaplamalarda girdi parametreleri, $d=100, 110, 120$ ve 130 mm; $d'=20$ mm; $A_s=679$ mm²; $f_{cd}=20$ MPa; $f_{yd}=420$ MPa ve $t=0, 5, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170$ ve 180 dakika olarak alınmıştır. Farklı d yüksekliklerinin yüksek ısıya maruz kalan döşemenin moment taşıma kapasitesi üzerindeki etkisi Şekil 5.1'de görülmektedir.

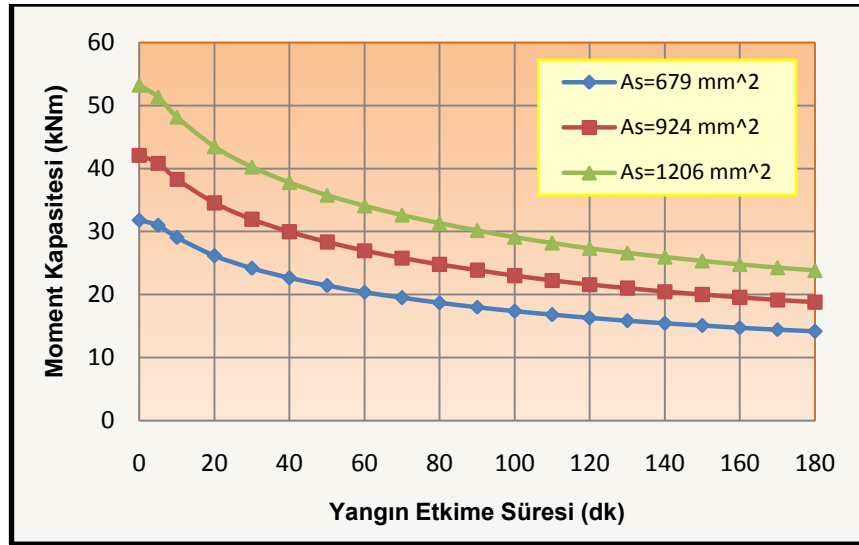


Şekil 5.1. Faydalı yüksekliğin moment taşıma kapasitesi üzerindeki etkisi

Faydalı yüksekliğin yüksek ısıya maruz kalan betonarme döşemenin moment taşıma kapasitesi üzerindeki olumlu etkisi yangının etkiye süresinin artmasıyla birlikte azalmaktadır. Yangın etkiye süresi 80 dakikayı geçtiğinde, döşeme faydalı yüksekliğinin moment taşıma kapasitesi üzerindeki etkisi önemini yitirmektedir.

5.1.2. Farklı donatı alanlarının moment kapasitesi üzerindeki etkisi

Bu kısımda, farklı donatı alanlarının moment kapasitesi üzerindeki etkisi incelenmiştir. Hesaplamalarda girdi parametreleri, $d=120$ mm; $d'=20$ mm; $A_s=679$, 924, 1206 mm²; $f_{cd}=20$ MPa; $f_{yd}=420$ MPa ve $t=0, 5, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170$ ve 180 dakika olarak alınmış ve farklı donatı alanlarının moment taşıma kapasitesi üzerindeki etkisi incelenmiştir. Analiz sonuçları Şekil 5.2'de görülmektedir.



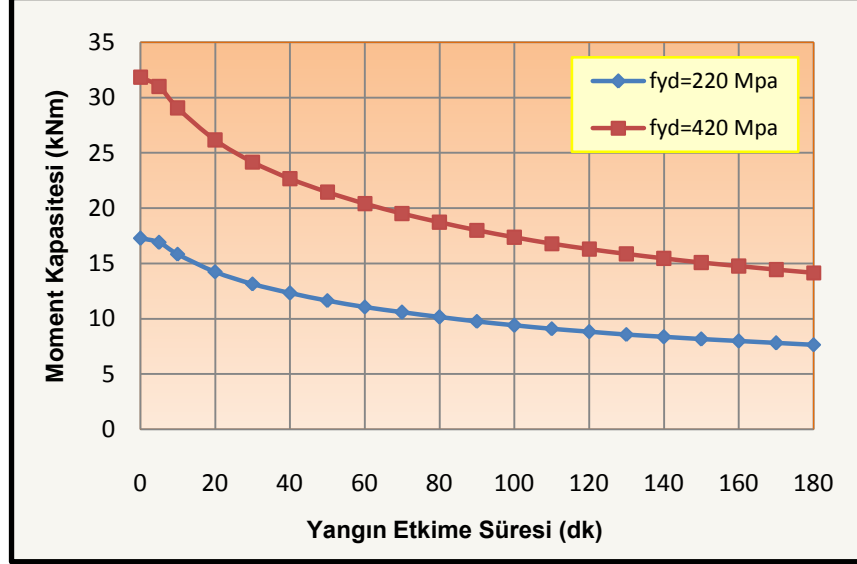
Şekil 5.2. Farklı donatı alanlarının moment taşıma kapasitesi üzerindeki etkisi

Şekil 5.2'den de görüldüğü gibi, donatı alanının moment kapasitesi üzerindeki etkisi kısa sürelidir ve yangın süresinin artmasıyla farklı donatı alanlarının moment kapasiteleri arasındaki fark yavaşça azalmaktadır. Yangına maruz kalma süresi 90 dakikayı geçtiğinde, donatı alanının moment taşıma kapasitesi üzerindeki etkisi büyük ölçüde azalmaktadır.

5.1.3. Farklı donatı dayanımlarının moment kapasitesi üzerindeki etkisi

Farklı akma dayanımına sahip donatıların taşıma gücü moment kapasitesi üzerindeki etkisi incelenerek Şekil 5.3'de gösterilmiştir. Hesaplamalarda girdi parametreleri $d=120$ mm; $d'=20$ mm; $A_s=679$ mm²; $f_{cd}=20$ MPa; $f_{yd}=220, 420$ MPa

ve $t=0, 5, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170$ ve 180 dakika olarak alınmıştır.

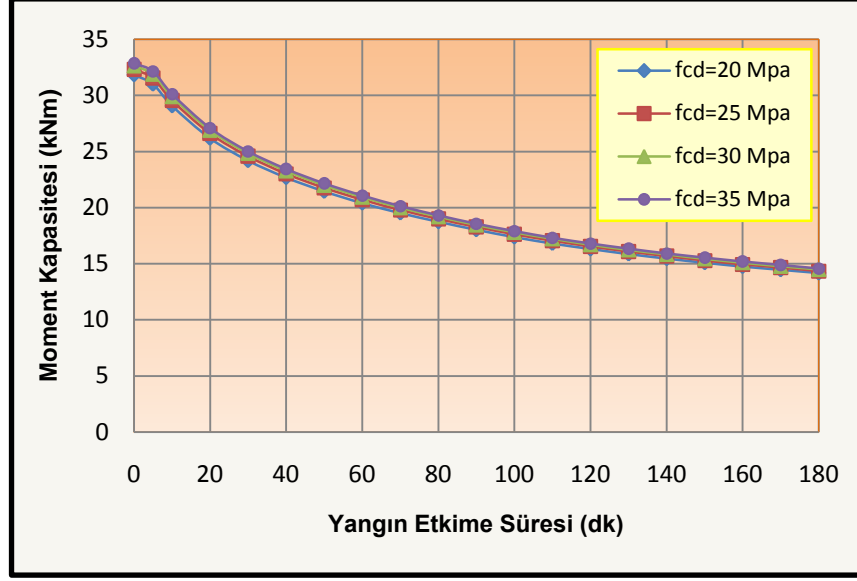


Şekil 5.3. Farklı donatı dayanımlarının moment taşıma kapasitesi üzerindeki etkisi

Şekil 5.3’de görüldüğü gibi, donatının akma dayanımının moment kapasitesi üzerindeki etkisi kısa süreli olmasına karşın, farklı akma dayanımına sahip donatıların moment kapasiteleri arasındaki fark yangının etkime süresinin artmasıyla azalmaktadır. Yangın etkime süresinin artmasıyla donatıdaki sıcaklık artmakta ve çelik malzemenin dayanımı azalmaktadır.

5.1.4. Farklı beton dayanımlarının moment kapasitesi üzerindeki etkisi

Farklı basınç dayanımına sahip betonların taşıma gücü moment kapasitesi analizinde girdi parametreleri $d=120$ mm; $d'=20$ mm; $A_s=679$ mm²; $f_{cd}=20, 25, 30$ ve 35 MPa; $f_{yd}=420$ MPa ve $t=0, 5, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170$ ve 180 dakika olarak alınmıştır. Farklı beton dayanımlarının moment taşıma kapasitesi üzerindeki etkisi Şekil 5.4’de grafiksel olarak gösterilmektedir.




Şekil 5.4. Farklı beton dayanımlarının moment taşıma kapasitesi üzerindeki etkisi

Analiz sonucunda beton basınç dayanımının moment kapasitesi üzerindeki etkisinin ihmal edilebilecek ölçüde az ve çok kısa süreli olduğu görülmüştür. Beton dayanımındaki değişimin moment kapasitesini önemli bir şekilde etkilememesinin nedeni beton basınç dayanımının çeliğinkinden daha düşük olmasıdır.

5.1.5. Farklı pas paylarının moment kapasitesi üzerindeki etkisi

Farklı pas paylarının yüksek ısıya maruz kalan betonarme döşemenin taşıma gücü moment kapasitesi üzerindeki etkisi YSA ve BSA ile irdelenirken girdi parametreleri $d=120$ mm; $d'=10, 20, 30$ ve 40 mm; $A_s=679$ mm²; $f_{cd}=20$ MPa; $f_{yd}=420$ MPa ve $t=0, 5, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170$ ve 180 dakika olarak alınmıştır. Farklı pas paylarının taşıma gücü moment kapasitesi üzerindeki etkisi Şekil 5.5'deki gibidir.



Şekil 5.5. Farklı pas paylarının moment taşıma kapasitesi üzerindeki etkisi

Şekil 5.5’de görüldüğü gibi farklı pas paylarına sahip yüksek ısıya maruz kalan döşemelerin taşıma gücü moment kapasiteleri arasındaki fark çok azdır. Dolayısıyla farklı pas paylarının taşıma gücü moment kapasitesi üzerindeki etkisi ihmal edilebilmektedir.

Yangına maruz farklı faydalı yüksekliğe, pas payına, donatı alanına, beton basınç dayanımına ve çelik akma dayanımına sahip betonarme döşemelerin taşıma gücü moment kapasitesi incelenmiş, YSA ve BSA metodu kullanılarak tahmin edilmiş ve bu parametrelerin etkisi araştırılmıştır. Yangına maruz kalan çeşitli özellikteki döşemelerin moment kapasiteleri hesaplanarak bir veri kümesi oluşturulmuştur. Oluşturulan 520 veri YSA ve BSA analizinde kullanılmıştır. Yapılan YSA analizinde korelasyon katsayısı eğitim aşamasında %99.678, test aşamasında %99.676 olarak; BSA analizinde eğitim aşamasında %98.250, test aşamasında %98.407 olarak elde edilmiştir. Bu değerler, kullanılan YSA ve BSA modelinin oldukça başarılı olduğunu göstermektedir. Ayrıca, test sonuçları YSA’nın BSA’dan daha başarılı sonuçlar ürettiğini göstermiştir. Yapılan bu çalışma ile çok fazla sayısal hesaplama ile uğraşmadan, eğitilmiş olan YSA ve BSA modeli kullanılarak yüksek doğruluk oranı ile moment kapasitesinin tahmin edildiği görülmektedir.

5.2. Öneriler

Bu tez çalışmasında, yüksek sıcaklık etkisine maruz betonarme döşemelerin taşıma gücü moment kapasitesini etkileyen parametreler olarak döşeme faydalı yüksekliği (d), pas payı (d'), donatı alanı (A_s), beton basınç dayanımı (f_{cd}), donatı akma dayanımı (f_{yd}) ve yangına maruz kalma süresi (t) dikkate alınmıştır. Elde edilen sonuçlar dikkate alındığında pas payının (d') etkisinin çok az olduğu görülmektedir. Yani, pas payını arttırmanın yangın etkisini azaltmada etkili olmayacağı analiz sonucundan anlaşılmaktadır. Bu konuda yeni yapılacak olan çalışmalarda, pas payı yerine daha etkili parametreler alınması daha uygun sonuçlar elde etmede etkili olabilir. Ayrıca betonarme döşemelerin izolasyonu, yangına karşı dayanım açısından pas payının arttırılmasına göre çok daha uygun sonuçlar verecektir.

Tez çalışmasında, bulanık sinir ağının yapay sinir ağına göre daha uygun sonuçlar vereceği beklenmekteydi. Ancak eldeki verilere göre, az farkla da olsa yapay sinir ağının daha uygun sonuçlar verdiği görülmektedir. Yapılacak olan yeni çalışmalarda, daha fazla veri dikkate alınarak bulanık sinir ağının performansı kontrol edilebilir.

KAYNAKLAR

- AKBULUT, S., HASİLOĞLU, A. S., and PAMUKCU, S., 2004. Data Generation for Shear Modulus and Damping Ratio in Reinforced Sands Using Adaptive Neuro-Fuzzy Inference System. *Soil Dynamics and Earthquake Engineering*, 24; 805–814.
- AKYILMAZ, O., AYAN, T., and ÖZLÜDEMİR, M. T., 2003. Geoid Surface Approximation by Using Adaptive Network Based Fuzzy Inference Systems. *Allgemeine Vermessungs-Nachrichten (AVN)*, 8-9; 308-315.
- BAİLEY, C. G., and ELLOBODY, E., 2009a. Fire Tests on Bonded Post-Tensioned Concrete Slabs. *Engineering Structures*, 31; 686-696.
- BAİLEY, C. G., and ELLOBODY, E., 2009b. Whole-Building Behaviour of Bonded Post-Tensioned Concrete Floor Plates Exposed to Fire. *Engineering Structures*, 31; 1800-1810.
- BİLGEHAN, M., 2010. A Comparative Study for the Concrete Compressive Strength Estimation Using Neural Network and Neuro-Fuzzy Modelling Approaches. *Nondestructive Testing and Evaluation*, DOI: 10.1080/10589751003770100.
- BİLGEHAN, M., and TURGUT, P., 2010a. Artificial Neural Network Approach to Predict Compressive Strength of Concrete through Ultrasonic Pulse Velocity. *Research in Nondestructive Evaluation*, 21(1); 1-17.
- BİLGEHAN, M., and TURGUT, P., 2010b. The Use of Neural Networks in Concrete Compressive Strength Estimation. *Computers and Concrete*, 7(3); 271-283.
- CHEN, B., LI, C., and CHEN, L., 2009. Experimental Study of Mechanical Properties of Normal-Strength Concrete Exposed to High Temperatures at An Early Age. *Fire Safety Journal*, 44; 997–1002.
- ÇENGEL, Y. A., 2002. *Heat Transfer: A Practical Approach*. McGraw-Hill, 896p.
- CREVIER, D., 1993. *AI: The Tumultuous Search for Artificial Intelligence*. NY: BasicBooks, New York, 386p.
- ÇETİN, M., UĞUR, A., ve BAYZAN, Ş., 2006. İleri Beslemeli Yapay Sinir Ağlarında Backpropagation (Geriye Yayılım) Algoritmasının Sezgisel Yaklaşımı. Ab2006 Akademik Bilişim Konferansı Bilgi Teknolojisi Kongresi IV, Pamukkale Üniversitesi, Denizli, Türkiye.
- EFE, M. Ö., and KAYNAK, O., 2004. *Yapay Sinir Ağları ve Uygulamaları*. Boğaziçi Üniversitesi, İstanbul, 141s.
- ELLOBODY, E., and BAİLEY, C. G., 2009. Modelling of Unbonded Post-Tensioned Concrete Slabs under Fire Conditions. *Fire Safety Journal*, 44; 159-167.
- ERDEM, H., 2008a. Nominal Moment Capacity of Box Reinforced Concrete Beams Exposed to Fire. *Turkish Journal of Engineering and Environmental Sciences*, 33; 31–44.
- ERDEM, H., 2008b. Betonarme Döşemelerin Taşıma Gücü Üzerinde Yüksek Sıcaklık Etkisi. Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi 30.Yıl Sempozyumu, 16-17 Ekim 2008, Adana, Türkiye.
- ERDEM, H., 2010. Prediction of The Moment Capacity of Reinforced Concrete Slabs in Fire Using Artificial Neural Networks. *Advances in Engineering Software*, 41; 270-276

- EUROCODE 2, 1995. Design of concrete structures, ENV 1992 Part 1-2: General Rules-Structural Fire Design, European Committee for Standardization, Brussels.
- GENCELİ, O. F., 2000. Çözümlü Isı İletimi Problemleri. Birsen Yayınevi, İstanbul, Türkiye, 491s.
- HOCAOĞLU, F. O., ve KURBAN, M., 2005. Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi ile Eskişehir Bölgesi için Güneşlenme Süreleri Tahmini. Elektrik-Elektronik-Bilgisayar Mühendisliği 11. Ulusal Kongresi ve Fuarı, İstanbul, 22-25 Eylül 2005.
- HOLA, J., and SCHABOWICZ, K., 2005. Application of Artificial Neural Networks to Determine Concrete Compressive Strength Based on Non-Destructive Tests. Journal of Civil Engineering And Management, 1; 23–32.
- ISO-834, 1975. Fire Resistance Tests-Elements of Building Construction Part 1-9, International Standards Organisation, Geneva.
- JANG, J. S. R., SUN, C. T., and MIZUTANI, E., 1997. Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence, Prentice Hall, 614p.
- JANG, J. S. R., 1993. ANFIS: Adaptive-Network Based Fuzzy Inference Systems. IEEE Trans. on Systems, Man, and Cybernetics, 23(03); 665-685.
- KARAHAN, O., TANYILDIZ, H., and ATIŞ, C. D., 2008. An Artificial Neural Network Approach for Prediction of Long-Term Strength Properties of Steel Fiber Reinforced Concrete Containing Fly Ash. Journal of Zhejiang University-SCIENCE A, 9(11); 1514-1523.
- KARLIK, B., 2003. Neural Network Image Recognition for Control of Manufacturing Plant. Mathematical & Computational Applications, 8(2); 181-189.
- KILIÇ, A., 2008. Çelik Taşıyıcıların Yangın Yalıtımı. Yangın ve Güvenlik, 118; 8-12.
- LEE, S. C., 2003. Prediction of Concrete Strength Using Artificial Neural Networks. Engineering Structures, 25; 849-857.
- MATLAB, 1999. The Language of Technical Computing. The Math Works Inc., Natick, MA, Version 6, USA, 432p.
- MINSKY, M. and PAPERT, S., 1969. Perceptrons. MIT Press, Cambridge.
- NARENDRA, K., and PARTHASARATHY, K., 1990. Identification and Control of Dynamical Systems Using Neural Networks, IEEE Trans. on Neural Networks, 1; 4-27.
- ÖZÇALIK, H. R., ve UYGUR, A. F., 2003. Dinamik Sistemlerin Uyumlu Sinirsel-Bulanık Ağ Yapısına Dayalı Etkin Modellenmesi. KSÜ Fen ve Mühendislik Dergisi 6(1); 36-46.
- ÖZGAN, E., KAP, T., BEYÇİOĞLU, A., ve EMİROĞLU, M., 2009. Asfalt Betonunda Marshall Stabilitesinin Uyarlamalı Sinirsel Bulanık Mantık Yaklaşımı ile Tahmini. 5. Uluslararası İleri Teknolojiler Sempozyumu (İATS'09), 13-15 Mayıs 2009, Karabük, Türkiye.
- ÖZSOY, İ., ve FIRAT, M., 2004. Kirişsiz Döşemeli Betonarme Bir Binada Oluşan Yatay Deplasmanın Yapay Sinir Ağlarıyla Tahmini. Dokuz Eylül Üniversitesi, Mühendislik Fakültesi, Fen ve Mühendislik Dergisi, 6(1); 51-63.
- ROJAS, R., 1996. Neural Networks-A Systematic Introduction. Springer-Verlag, Berlin, Germany, 502p.

- SAGIROĞLU, Ş., BEŞDOK, E., ve ERLER, M., 2003. Mühendislikte Yapay Zeka Uygulamaları-I: Yapay Sinir Ağları. Ufuk Yayıncılık, Kayseri, 426s.
- TANYILDIZI, H., 2009. Fuzzy Logic Model for Prediction of Mechanical Properties of Lightweight Concrete Exposed to High Temperature. *Materials and Design*, 30; 2205–2210.
- TOPÇU, I. B., KARAKURT, C., and SARIDEMİR, M., 2008. Predicting the Strength Development of Cements Produced with Different Pozzolans by Neural Network and Fuzzy Logic. *Materials and Design*, 29; 1986–91.
- TOPÇU, I. B., ve SARIDEMİR, M., 2007. Prediction of Properties of Waste AAC Aggregate Concrete Using Artificial Neural Network. *Computational Materials Science*, 41; 117–125.
- TSOUKALAS, L. H. and UHRIG, R. E., 1996. *Fuzzy and Neural Approaches in Engineering*. Jhon Wiley & Sons , New York, 606p.
- UYGUNOĞLU, T., and YURTCU, Ş., 2006. Yapay Zeka Tekniklerinin İnşaat Mühendisliği Problemlerinde Kullanımı. *Yapı Teknolojileri Elektronik Dergisi*, 2006(1); 61–70
- YURTOĞLU, H., 2005. Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği. Devlet Planlama Teşkilatı, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, Uzmanlık Tezi, Yayın No: DPT: 2683, 113s.
- ZADEH, L. A., 1965. Fuzzy Sets. *Information and Control*, 8(3); 338-352.
- XU, Y., and WU, B., 2009. Fire Resistance of Reinforced Concrete Columns with L-, T-, And +- Shaped Cross-Sections. *Fire Safety Journal*, 44; 869–880.
- www.bilimge.com/index.php/component/content/article/68-yapay-sinir-aglari/830-yapay-sinir-aglari.html
- www.tr.wikipedia.org/wiki/Yapay_sinir_a%C4%9Flar%C4%B1
- www.tr.wikipedia.org/wiki/Yapay_zek%C3%A2#Alt_dallar

ÖZGEÇMİŞ

Mihriban Karamanođlu, 1984 yılında Siverek'te doğdu. İlköğrenimini Mersin'de, ortaöğrenimini Şanlıurfa'da tamamladı. 2007 yılında Harran Üniversitesi İnşaat Mühendisliđi Bölümünden, Mühendislik Fakültesi 3.'sü olarak mezun oldu. Aynı yıl Harran Üniversitesi İnşaat Mühendisliđi Anabilim Dalı'nda yüksek lisans eğitimine başladı ve halen yüksek lisans eğitimine devam etmektedir.

ÖZET

Bu yüksek lisans tez araştırması, yüksek ısıya maruz kalan betonarme döşemelerin taşıma gücü moment kapasitesinin, çok ve karmaşık hesaplamalara gerek kalmadan belirlenebilmesi için YSA ve ANFIS'in tahmin etme kabiliyetini araştırmaktadır. Geliştirilen YSA ve ANFIS modellerinde kullanılmak ve bu modellerin tahmin etme kapasitelerini kıyaslamak amacıyla farklı yangın etkime sürelerine maruz kalan farklı faydalı yüksekliğe (d), pas payına (d'), donatı alanına (A_s), beton basınç dayanımına (f_{cd}) ve donatı akma dayanımına (f_{yd}) sahip betonarme döşemelerin eğilme kapasiteleri, yangına maruz kalma süresi (t) dikkate alınarak hesaplanmıştır. Farklı özellikteki betonarme döşemelerin eğilme kapasitesi hesaplanırken yangının etkime süresine bağlı olarak ortaya çıkan yüksek ısı, ISO834 (1975)'de verilen bağıntı ile hesaplanmıştır. Döşeme içerisindeki ısı dağılımı bir boyutlu ısı geçişi kabulü ile modellenmiş ve döşeme kesiti dilimlere ayrılmıştır. Her bir dilimde ortaya çıkan yüksek ısı belirlenmiş ve Eurocode 2 (1995)'de verilen malzeme azaltma katsayıları kullanılarak ortaya çıkan yüksek ısı altında azalan malzeme dayanımları ve kuvvetler hesaplanmıştır. Dilimlerdeki kuvvetlerin dengesinden döşemenin eğilme kapasitesi hesaplanmıştır. Hesaplanan eğilme kapasiteleri değerlerinden oluşturulan veri kümesi YSA ve ANFIS modelinde kullanılmıştır. 520 adet veri setinden oluşan bu veri kümesinin %55'i eğitim, %45'i ise test aşamasında kullanılmıştır. YSA modelinde ağırlık yapısı ileri beslemeli geri yayımlı sinir ağı, eğitim algoritması olarak LM sinir ağı dikkate alınmıştır. Girdi parametreleri d , d' , A_s , f_{cd} , f_{yd} ve t olarak; çıktı parametresi döşemenin eğilme kapasitesi olarak (M_u) belirlenmiştir. Bu çalışma sonucunda, YSA'da eğitim aşamasında korelasyon katsayısı (R) 0.99678, karesel hataların ortalama karekökü ($RMSE$) 0.44119 ve ortalama taraflı hata (MBE) 0.00215; test aşamasında korelasyon katsayısı (R) 0.99676, karesel hataların ortalama karekökü ($RMSE$) 0.40896 ve ortalama taraflı hata (MBE) 0.00314 olarak elde edilmiştir. ANFIS'te ise eğitim aşamasında korelasyon katsayısı (R) 0.98250, karesel hataların ortalama karekökü ($RMSE$) 1.02908 ve ortalama taraflı hata (MBE) 0.00001; test aşamasında korelasyon katsayısı (R) 0.98407, karesel hataların ortalama karekökü ($RMSE$) 1.01951 ve ortalama taraflı hata (MBE) 0.09552 olarak elde edilmiştir. Elde edilen sonuçlar YSA

ve ANFIS'in oldukça yüksek bir doğrulukla başarılı sonuçlar ürettiğini göstermektedir. Ayrıca YSA ve ANFIS'in ürettiği sonuçlar karşılaştırıldığında, bu çalışma için YSA'nın tahmin etme kabiliyetinin ANFIS'e göre daha uygun olduğu görülmektedir.

Bu tez çalışması ile görülmüştür ki, çok fazla sayısal hesaplama ile uğraşmadan, eğitilmiş olan YSA ve BSA modeli kullanılarak yüksek ısıya maruz kalan betonarme döşemelerin moment kapasitesi, yüksek doğruluk oranı ile tahmin edilebilmektedir.

SUMMARY

This master's thesis examines the predicting capabilities of YSA and ANFIS, used for determining the ultimate moment capacity of the reinforced concrete slabs which are exposed to high temperatures, without needing many and complex steps for calculation. With the purpose using them in the developed YSA and ANFIS models and for the comparison of the predicting capacities of these models, the ultimate moment capacities of the reinforced concrete slabs, which were exposed to different fire affection periods, with different effective depths (d), distance values from the extreme fiber in tension to the centroid of the steel on the tension side of the slab (d'), areas of reinforcement on the tension face of the slab (A_s), compressive strengths (f_{cd}), and yield strengths (f_{yd}) were calculated by considering their fire exposure time (t) values. While calculating the moment capacities of the slabs, the high value of the heat generated, in relation with the affection period of the fire, was calculated with the correlation presented in ISO834 (1975). The heat distribution in the slab was modeled with a single dimensional heat transfer assumption; and the slab section was cut into slices. The high value of heat generated in each slice was determined; and the material strengths and forces obtained when exposed to high temperatures were calculated by using the reduction coefficient of the material presented in Eurocode 2 (1995). The ultimate moment capacity of the slab was then calculated by using the balance of the forces in the slices. The data pile, consisting of the calculated moment capacity values, was used in the YSA and ANFIS models. 55% of this data pile, consisting of 520 data sets, was used in the training process while the 45% of the data was utilized in the test process. In the YSA model, the structure of the network was feedforward neural network while LM neural network was considered for the training algorithm. The input parameters were determined as d , d' , A_s , f_{cd} , f_{yd} , and t whereas the output parameter was designated as the ultimate moment capacity (M_u) of the slab. As a result of this study, the correlation coefficient (R) was obtained as 0.99678; the root mean square error ($RMSE$) was 0.44119; and the mean bias error (MBE) was calculated as 0.00215 in the training process of YSA. Likewise, in the test process of YSA, the correlation coefficient (R) was obtained as 0.99676; the root mean square error ($RMSE$) was 0.40896; and the mean bias error

(*MBE*) was calculated as 0.00314. For ANFIS, on the other hand, the correlation coefficients (*R*) were calculated as 0.98250 and 0.98407; the root mean square error (*RMSE*) were 1.02908 and 1.01951; and the mean bias error (*MBE*) values were obtained as 0.00001 and 0.09552, respectively, in the training and test processes of the model. These results obtained show that YSA and ANFIS produce results with a significantly high level of accuracy. Moreover, when the results produced by YSA and ANFIS are compared, for this study, it is observed that the prediction capability of YSA was more compatible than ANFIS.

With this thesis study, it was seen that, by using trained YSA and BSA models, the ultimate moment capacity of the slabs exposed to high temperatures can be predicted with a high accuracy level without dealing with many numerical calculations.