

**BETONUN KIRILMASINDA ÇİFT-K YAKLAŞIMININ
YAPAY SİNİR AĞLARIYLA MODELLENMESİ**

İnş. Müh. Cenk FENERLİ

**Yüksek Lisans Tezi
İnşaat Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Ragıp İNCE
EYLÜL-2013**

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

**BETONUN KIRILMASINDA ÇİFT-K YAKLAŞIMININ
YAPAY SİNİR AĞLARIYLA MODELLENMESİ**

YÜKSEK LİSANS TEZİ

İnş. Müh. Cenk FENERLİ

(101115106)

Tezin Enstitüye Verildiği Tarih : 04 Eylül 2013

Tezin Savunulduğu Tarih : 25 Eylül 2013

Tez Danışmanı : Prof. Dr. Ragıp İNCE (F.Ü)

Diğer Jüri Üyeleri : Prof. Dr. Zülfü Çınar ULUCAN (F.Ü)

Yrd. Doç. Dr. Erdinç ARICI (F.Ü)

EYLÜL-2013

ÖNSÖZ

Bu tez çalışmasında bana yol gösteren, bilgi birikimi ve tecrübesi ile destek olup, anlayışını benden esirgemeyen gerek üniversite gerekse akademik hayatım boyunca etkisi olan tez danışmanım Prof. Dr. Ragıp İNCE' ye en içten saygı ve teşekkürlerimi sunarım.

Tez çalışmamda tecrübesi ve manevi desteğiyle yanımda olan Y. Mimar A. Turan ÜZMEZ' e,

Çalışmam boyunca bana verdiği desteklerden dolayı Prof. Dr. Mehmet ÖNAL ve Hekimhan Meslek Yüksekokulundaki çalışma arkadaşlarıma teşekkür ederim.

Hayatımın her aşamasında maddi ve manevi olarak bana destek veren, bana her daim inanan aileme sonsuz teşekkürler ederim.

Cenk FENERLİ
ELAZIĞ-2013

İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	II
İÇİNDEKİLER.....	III
ÖZET	VI
SUMMARY	VII
ŞEKİLLER LİSTESİ.....	VIII
TABLolar LİSTESİ	X
SEMBOLLER LİSTESİ.....	XI
KISALTMALAR LİSTESİ.....	XIII
1. GİRİŞ.....	1
2. MATERYAL VE METOT	3
2.1. Kırılma mekaniği.....	3
2.1.1. Kırılma Mekaniğine Giriş.....	3
2.1.2. Kırılma Mekaniğinin Tarihi ve Gelişimi	4
2.1.3. Lineer Elastik Kırılma Mekaniği (LEKM).....	6
2.1.4. Lineer Olmayan Elastik Kırılma Mekaniği	11
2.2. Betonun Kırılma Mekaniği.....	12
2.2.1. Giriş	12
2.2.2. Betonun Kırılma Mekaniğinin Tarihsel Süreci	15
2.2.3. Betonda Kırılma Süreci Bölgesi	16
2.2.4. Çatlak Yayılmasını Önleyici Faktörler.....	20
2.3. Efektif Çatlak Modelleri.....	22
2.3.1. Efektif Çatlak Modeli (EÇM).....	22
2.3.1.1. Efektif Kritik Çatlak Uzunluğu (ae)	24
2.3.2. Çift-K Modeli	25
2.4. Yapay Sinir Ağları.....	29
2.4.1. Yapay Sinir Ağlarının Tanımı	29
2.4.2. Yapay Sinir Ağlarının Özellikleri.....	31
2.4.2.1. Bellek ve Genelleme.....	32
2.4.2.2. Eksik Bilgilerle Çalışabilme	32

2.4.2.3. Doğrusal Olmama ve Paralellik.....	33
2.4.2.4. Öğrenme	33
2.4.2.5. Adaptasyon	34
2.4.2.6. Sınırsız Sayıda Değişken ve Parametre Kullanma	34
2.4.2.7. Hataya ve Gürültüye Karşı Duyarlılık ve Tolerans:	34
2.4.3. Yapay Sinir Ağlarının Yapısı ve Temel Bileşenleri	34
2.4.3.1. Biyolojik Sinir Hücresi Yapısı	34
2.4.3.2. Yapay Sinir Hücresi Yapısı	37
2.4.3.2.1. Girdiler	38
2.4.3.2.2. Ağırlıklar	38
2.4.3.2.3. Toplama Fonksiyonu	39
2.4.3.2.4. Transfer Fonksiyonu.....	39
2.4.3.2.4.1. Hard-Limit Transfer Fonksiyonu	40
2.4.3.2.4.2. Lineer Transfer Fonksiyonu	41
2.4.3.2.4.3. Log-Sigmoid Transfer Fonksiyonu	41
2.4.3.2.4.4. Hiperbolik Tanjant Transfer Fonksiyonu	42
2.4.3.2.5. Çıkış İşlevi.....	42
2.4.4. Yapay Sinir Ağlarının Sınıflandırılması.....	43
2.4.4.1. Yapay Sinir Ağlarının Yapılarına Göre Sınıflandırılması.....	43
2.4.4.1.1. İleri Beslemeli Yapay Sinir Ağları	43
2.4.4.1.1.1. Çok Katmanlı Nöral Ağ Yapısı (MLP)	44
2.4.4.1.1.2. Öğrenme Vektör Nicelendirilmesi (Learning Vector Quantization) Ağı.....	45
2.4.4.1.2. Geri Beslemeli Yapay Sinir Ağları.....	45
2.4.4.1.2.1. Elman Ağı.....	46
2.4.4.1.2.2. Hopfield Ağı.....	48
2.4.4.1.2.3. Uyarlanır Rezonans Ağı (ART).....	48
2.4.4.1.2.4. Som Ağı.....	48
2.4.4.1.3. İleri Beslemeli Geri Yayılmalı Ağlar	49
2.4.4.2. Öğrenme Algoritmalarına Göre Ağ Çeşitleri	49
2.4.4.2.1. Danışmalı Öğrenme.....	50
2.4.4.2.1.1. Geri Yayılımlı Öğrenme Kuralı.....	51
2.4.4.2.1.1.1. Geri Yayılım Algoritması.....	51
2.4.4.2.2. Danışmasız Öğrenme.....	55

2.4.4.2.3. Destekleyici Öğrenme	55
2.4.5. Yapay Sinir Ağları Temel Öğrenme Kuralları	55
2.4.5.1. Hebb Kuralı	55
2.4.5.2. Hopfield Kuralı.....	56
2.4.5.3. Delta Kuralı	56
2.4.5.4. Kohonen Kuralı	56
2.4.6. Levenberg-Marquardt Algoritması.....	56
2.4.7. Yapay Sinir Ağlarının İnşaat Mühendisliğinde Uygulamaları	59
3. BETONUN KIRILMASINDA ÇİFT-K YAKLAŞIMININ YAPAY SİNİR AĞLARIYLA MODELLENMESİ	61
3.1. Giriş	61
3.2. Yapay Sinir Ağ Modeli	61
3.3. Yapay Sinir Ağının Eğitilmesi ve Test Edilmesi.....	63
4. SONUÇ VE ÖNERİLER	71
KAYNAKLAR.....	73
EKLER	86
Ek-1 Betonun Kırılmasında Çift-K Yaklaşımının Yapay Sinir Ağlarıyla Modellenmesinde Kullanılan Matlab Programı	86
ÖZGEÇMİŞ.....	90

ÖZET

Çatlamış bir yapı en iyi kırılma mekaniği prensipleri kullanılarak analiz edilebilir. Kırılma mekaniğine göre herhangi bir yapıyı analiz edebilmek için ise, ilk önce malzemenin kırılma parametrelerinin bilinmesi gerekir. Yapılan deneysel çalışmalar, betonun kırılma parametreleri üzerine beton basınç mukavemeti, su/çimento oranı, maksimum agrega çapı ve agrega tipinin etkili olduğu tespit edilmiştir.

Betonun kırılma parametrelerini belirlemek için şartnameler ve araştırmacılar tarafından birçok lineer olmayan kırılma mekaniği modelleri önerilmektedir. Çift-K modeli, beton yapılarda kırılmayı modellemek için başlangıç gerilme şiddet çarpanı K_{Ic}^{ini} ve kritik gerilme şiddet çarpanı K_{Ic}^{un} gibi iki parametre kullanmaktadır. Yöntemin diğer kırılma modellerinden en önemli farkı, diğer kırılma modellerinde sadece çatlağın ani gelişimini dikkate alan parametreler ile beton yapılar modellenirken, Çift-K yönteminde buna ilave olarak çatlağın yayılmaya başlama kriterini de dikkate almasıdır.

Yapay Sinir Ağları (YSA) yaklaşımı kullanmanın ana faydası ağın deneysel verilerle kendi kendine organize yeteneğini kullanarak inşa olmasıdır. Sunulan kırılma modeli literatürde bulunan farklı 193 gürültülü test verileri kullanılarak farklı laboratuvarlarda yapılan test datalarından geliştirilmiştir.

Çalışmada betonun malzeme parametreleri; agrega tipi, maksimum agrega çapı, betonun basınç mukavemeti, su/çimento oranı ve malzemenin geometrik parametresi başlangıç çatlak boyu (a_0) ile etkili çatlak boyu a_e ve Çift-K modelindeki başlangıç gerilme şiddet çarpanı faktörü K_{Ic}^{ini} kırılma parametreleri arasında yapay sinir ağları tabanlı bir ilişki kurulması amaçlanmıştır. Sonuçların uygulanabilir ve umut verici olduğu görülmüştür.

Anahtar Kelimeler: Beton, Kırılma Mekaniği, Çift-K Modeli, Yapay Sinir Ağları

SUMMARY

Modelling of Double-K Fracture Approach in Concrete Fracture by Artificial Neural Networks

A cracked building can only be analyzed the best way utilizing the principals of fracture mechanics. To analyze a concrete a structure according to fracture mechanics, fracture parameters of cementitious material must be determined. Experimental studies have shown that fracture parameters of concrete are particularly influenced by the four material parameters compressive strenght, maximum aggregate size, water-cement ratio and aggregate type.

Many non-linear fracture models have been proposed by design codes and investigators to determine fracture parameters of concrete. To characterize failure of concrete structures, the Double-K Model needs two fracture parameters: the unstable stress intensity factor K_{Ic}^{un} and the initiation stress intensity factor K_{Ic}^{ini} . The most important difference from the other models of fracture method, on the other fracture models, taking into account not only the development of the sudden crack of concrete structures modeled with parameters, in addition to double-K method is that it takes into account the criteria of the crack initiation to spread.

The main benefit of using an Artificial Neural Network (ANN) approach is that the network is built directly on experimental data by using the self-organizing capabilities of the ANN. The presented fracture model was developed by utilising 193 noisy test data taken from the literature, which were obtained via different test methods in different laboratories.

In the study of the concrete material parameters; aggregate type, maximum aggregate size (d_{max}), compressive strength of concrete (f_c), water-cement ratio (w/c) geometric parameters of material; the initial crack length (a_0) and the effective crack length (a_e) and the initiation stress intensity factor K_{Ic}^{ini} in double-K model is to establish a relationship based on artificial neural networks. The results of an ANN-based ECM look viable and very promising.

Key words: Concrete, Fracture Mechanics, Double-K Model, Artificial Neural Networks

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 2.1. Kırılma modları	9
Şekil 2.2. Kırılma süreci bölgesi	10
Şekil 2.3. Betonda kullanılan lineer olamayan modeller [12].	14
Şekil 2.4. Betonun basınç altında diyagramatik gerilme-şekil değiştirme eğrisi	17
Şekil 2.5. a) Çekmeye maruz bir numunenin yük-deformasyon diyagramı. b) Kırılma süreci bölgesi [72].	18
Şekil 2.6. Kırılma süreci bölgesinin gelişimi [72].	19
Şekil 2.7. Değişik malzeme sınıfları için L:lineer, N:non-lineer ve K:kırılma süreci bölgeleri	19
Şekil 2.8. Sünek ve Yarı gevrek malzemede çatlak ucunda meydana gelen durumlar	20
Şekil 2.9. Betonda tokluk artışına neden olan mekanizmalar.....	21
Şekil 2.10. Efektif çatlak modeli	23
Şekil 2.11. Çift-K modelde kırılma parametrelerinin tayini [12].	27
Şekil 2.12. Basit bir yapay sinir ağı yapısı	29
Şekil 2.13 Bir yapay sinir ağının tipik olarak bağlantı şekli	32
Şekil 2.14 Biyolojik sinir sistemi blok gösterimi	35
Şekil 2.15 Biyolojik nöron yapısı	36
Şekil 2.16. Yapay sinir hücresinin yapısı	38
Şekil 2.17. Hard-limit transfer fonksiyonu	40
Şekil 2.18. Lineer transfer fonksiyonu	41
Şekil 2.19. Log-Sigmoid transfer fonksiyonu	41
Şekil 2.20. Hiperbolik tanjant transfer fonksiyonu.....	42
Şekil 2.21. İleri beslemeli ağ	43
Şekil 2.22. Çok katmanlı yapay sinir ağı yapısı	44
Şekil 2.23. Geri beslemeli yapay sinir ağı yapısı [81].	46
Şekil 2.24. Elman ağ yapısı	47
Şekil 2.25. Danışmalı öğrenme	50
Şekil 2.26. a) Geri yayılım ağı, b) Sigmoid fonksiyonu c) Yapay sinir ağının matematiksel modellenmesi.....	52

Şekil 3.1. Çalışmada oluşturulan yapay sinir ağı yapısı	62
Şekil 3.2. Yapay Sinir ağıının iterasyona bağlı hata değişim grafiği	68
Şekil 3.3. Deneysel K_{Ic}^{ini} değerleri ile YSA K_{Ic}^{ini} değerlerinin karşılaştırılması.....	69
Şekil 3.4. Deneysel ae/d değerleri ile YSA ae/d değerlerinin karşılaştırılması.....	70

TABLÖLAR LİSTESİ

Sayfa No

Tablo 2.1. Biyolojik sinir sistemi ile yapay sinir ağlarının benzerlikleri [84].....	37
Tablo 3.1 Yapay sinir ağları eğitim seti	63
Tablo 3.2. Yapay sinir ağları doğrulama seti.....	66
Tablo 3.3. Yapay sinir ağları test seti	66
Tablo 3.4. YSA ile ilgili parametreler	67
Tablo 3.5. Yapay sinir ağları test seti sonuçları	69

SEMBOLLER LİSTESİ

a_0	: Başlangıç çatlak boyu
a_c	: Kritik çatlak boyu
a_e	: Çatlağın efektif uzunluğu
b	: Kirişin eni
c_f	: Sonsuz modeller için kritik etkin kırılma genişlemesi
C	: Kırma taş agregası
C_i	: İlk komplians değeri
C_s	: Son komplians değeri
d	: Kirişin yüksekliği
d_{max}	: Maksimum agregası dane çapı
E	: Elastisite modülü
f_t	: Malzemenin çekme dayanımı
f_c	: Malzemenin basınç dayanımı
G_c	: Çatlak yayılma hızı
G_f	: Gerilme tokluğu
K_c	: Kritik gerilme yoğunluğu
K_I	: Gerilme şiddet çarpanı
K_{Ic}^e	: Efektif gerilme şiddet çarpanı
K_{Ic}^{ini}	: Başlangıç gerilme şiddet çarpanı
K_{Ic}^{un}	: Kritik gerilme şiddet çarpanı
K_{Ic}^c	: Kohezif gerilme şiddet çarpanı
K_{Ic}^s	: Kritik gerilme yığılma faktörü
K_{Ic}	: Açılma modu kırılma tokluğu
K_{IIc}	: Kayma modu kırılma tokluğu
K_{IIIc}	: Yırtılma modu kırılma tokluğu
P	: Uygulanan yük
R	: Doğal agregası
S	: Yükleme mesafesi
P_{ini}	: İlk çatlama yükü

P_{max}	: Kırılma yükü
r_y	: Kırılma süreci bölgesi uzunluğu
w/c	: Su/çimeto oranı
σ_N	: Nominal dayanım
σ	: Normal gerilme
ε	: Şekil değiştirme
τ	: Kayma gerilmesi
w	: Çatlak açılımı deplasmanı
w_c	: Kritik çatlak açılımı deplasmanı
σ_y	: Malzemenin akma dayanımı
γ	: Yüzey incelemesi

KISALTMALAR LİSTESİ

ART	: Uyarlanır Rezonans Ağı
BEM	: Boyut Etkisi Modeli
CMOD	: Çatlak Ağız Açılımı Deplasmanı
CTOD	: Çatlak Ucu Açılımı Deplasmanı
$CTOD_c$	: Kritik Çatlak Ucu Açılım Deplasmanı
ÇBM	: Çatlak Bant Modeli
EÇM	: Efektif Çatlak Modeli
FÇM	: Fiktif Çatlak Modeli
EPKM	: Elasto Plastik Kırılma Mekaniği
FÇM	: Fiktif Çatlak Modeli
İPM	: İki Parametrelili Model
KSB	: Kırılma Süreci Bölgesi
KİE	: Kırılma İş Enerjisi
LEKM	: Lineer Elastik Kırılma Mekaniği
LM	: Levenberg-Marquardt Eğitim Algoritması
MLP	: Çok Katmanlı Ağ
MSE	: Ağı Karesel Ortalama Hatası
P-CMOD	: Yük-Çatlak Ağız Açılımı Deplasmanı
RILEM	: Avrupa Laboratuvar Birliği
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Kırılma mekaniği temelde, malzemede var olan çentik, çatlak ve boşluk gibi gerilme yoğunluğunu arttıran kusurları ve bunlara bağlı olarak meydana gelen hasarları inceler. İlk olarak Griffith [1] tarafından temeli atılan Lineer Elastik Kırılma Mekaniği (LEKM) teorisi, 1960'lı yılların başında Kaplan [2] tarafından betona uygulanmıştır. Ancak daha sonra yapılan deneysel çalışmalar, LEKM kanunlarının beton için yetersiz olduğunu göstermiştir [3]. Bu amaçla birçok araştırmacı tarafından teknolojik ve nümerik alanlardaki gelişmelere paralel olarak, lineer olmayan kırılma mekaniği yaklaşımları geliştirilmiştir [4-8].

Bu yaklaşımlar temelde, çatlamış bir beton kesitte gerilme transferini mümkün kılan, kırılma süreci bölgesinin varlığını dikkate alırlar. Yapı şartnameleri ve LEKM tarafından ihmal edilen bu bölge, metallerde plastik bölgenin yanında çok küçük olmasına karşın, betonda 100 mm'nin üzerinde değerler alarak büyük yer işgal ederler [9]. Diğer taraftan bu bölgedeki gerilmeler, metallerdeki plastik bölgeden farklı olarak, sabit kalmayıp azalmaktadır. Bu davranışı karakterize etmek için LEKM nin aksine, lineer olmayan kırılma mekaniği yaklaşımları betonu modellemek için en az iki parametre kullanırlar.

Çift-K Modeli, beton yapılarda kırılmayı modellemek için başlangıç gerilme şiddet çarpanı K_{IC}^{ini} ve kritik gerilme şiddet çarpanı K_{IC}^{un} gibi iki parametre kullanmaktadır [10-11]. Yöntemin diğer kırılma modellerinden en önemli farkı, diğer kırılma modellerinde sadece çatlağın ani gelişmesini dikkate alan parametreler ile beton yapılar modellenirken, Çift-K yönteminde buna ilave olarak çatlağın yayılmaya başlama kriterini de dikkate almasıdır. Bununla beraber Çift-K yönteminde K_{IC}^{ini} parametresini belirlemek için kohezif gerilme şiddet çarpanı K_{IC}^c ifadesini kullanmaktadır. K_{IC}^c ise bazı ampirik ifadelerle dayanmakta ve hesabında nümerik integral tekniklerine başvurulmaktadır. Bununla birlikte son zamanlarda, K_{IC}^c nin hesabı için direkt integrallenebilir, yarı-analitik bir yöntem, İnce [12] tarafından geliştirilmiş ve literatürden elde edilen 94 deney verisi kullanılarak yöntem test edilmiş ve analitik yaklaşımın sonuçlarının oldukça uygun ve ümit verici olduğu tespit edilmiştir. İnce [109] Çift-K yöntemi ile yarma-çekme deneylerinde kübik ve silindir

numuların kırılma parametrelerini üzerine çalışmalar yapmış ve mevcut deney sonuçlarıyla karşılaştırıldığında sonuçların oldukça müspet olduğu görülmüştür.

Yapılan deneysel çalışmalar, betonun kırılma parametreleri üzerine betonun basınç mukavemeti, su/çimento oranı, maksimum agrega çapı ve agrega tipinin etkili olduğunu göstermektedir [13-14].

Bu konuda, Bazant ve Becq-Giraudon regrasyon analizi yaparak boyut etkisi modelinin (BEM) kırılma parametreleri (G_f ve c_f) ile malzeme parametreleri (basınç mukavemeti, su/çim oranı, maksimum agrega çapı ve agrega tipi-nehir/kırmataş) arasında ilişki bulmaya çalışmıştır [13]. Benzer olarak İnce [14,108] yapay sinir ağları kullanarak sırasıyla İPM (K_{Ic}^s ve $CTOD_c$) ve EÇM (K_{Ic}^e ve a_e) kırılma parametreleri ile malzeme parametreleri arasında ilişki bulmaya çalışmış ve oldukça müspet sonuçlar elde etmiştir.

Mühendislik problemlerinde YSA'nın en önemli özelliği örneklerden doğrudan öğrenebilme yeteneğinin olmasıdır. YSA ların diğer önemli özelliği tamamlanmamış görevler için doğru veya doğruya yakın cevap vermeleri, gürültülü veya kötü verilerden sonuç çıkarmaları ve meydana gelmiş durumlardan genelleştirilmiş sonuç üretmeleridir [107]. Yukarıda bahsedilen özellikler yapay sinir ağlarının birçok mühendislik parametresinin çözümünde çok güçlü bir araç haline getirmiştir. Özellikle verilerin karmaşık ve yetersiz miktarda olduğu durumlarda YSA büyük önem arz etmektedir. Son on yıl içinde yapay sinir ağları çimento esaslı malzemelerin kırılma mekaniğinde, kırılma tokluğu tahmininde, malzemelerin yorulma ve beton teknolojisinde başarı performansı göstermiştir.

Bu çalışmada Efektif çatlak modeli (EÇM) yaklaşımlarını izleyen çimento esaslı malzemelerin kırılma parametrelerini tahmin etmek için yapay sinir ağı tabanlı bir kırılma modeli sunulmuştur. Yapay sinir ağı modeli mevcut literatürden alınan 193 gürültülü test verileri kullanılarak geliştirilmiştir. Efektif çatlak modeli (EÇM) ye göre betonun kırılma parametrelerini tahmin etmek için önerilen kırılma modelinde dört malzeme parametresi ve bir geometrik parametre kullanılmıştır.

Bu model başlangıç gerilme şiddet çarpanı faktörü K_{Ic}^{ini} yi ve etkili çatlak boyu a_e kırılma parametrelerini esas almaktadır. Çalışmada betonun malzeme parametreleri (agrega tipi, maksimum agrega çapı, betonun basınç mukavemeti, su/çimento oranı) ve bir geometrik parametre başlangıç çatlak boyu a_0 ile etkili çatlak boyu a_e ve Çift-K modelindeki başlangıç gerilme şiddet çarpanı faktörü K_{Ic}^{ini} kırılma parametreleri arasında yapay sinir ağları tabanlı bir ilişki kurulması amaçlanmıştır.

2. MATERYAL VE METOT

2.1. Kırılma mekaniği

2.1.1. Kırılma Mekaniğine Giriş

Katı bir cismin gerilmeler altında iki veya daha çok parçaya ayrılması olayı ‘Kırılma’ olarak adlandırılır. Kırılma olayı, bir çatlağın başlaması ve ilerlemesi olarak iki kısımda incelenir. Yük taşıyan yapılarda hasar, en genel anlamda akma veya kırılmayla olur. Bir malzemenin yapısındaki hatalar iki tip hasar için de çok önemlidir, fakat aralarında önemli farklar vardır. Akmayla oluşan hasarda önemli olan hatalar, kristal kafesi düzlemlerinin sürekliliğini bozan ve dislokasyon hareketini engelleyen hatalardır. Bu da metallerdeki mukavemet artışı için gerekli bir olaydır. Kırılmayla oluşan hasarda önemli olan hatalar ise makroskobik boyuttadır, çünkü genel bir plastik deformasyon değil, hatalarla bağıntılı olan yerel gerilme-şekil değiştirme alanları söz konusudur (malzeme yapısındaki boşluklar, kaynak hataları ve yorulma çatlakları gibi). Kırılma genellikle gevrek ve sünek olarak iki grupta ele alınır [15].

Sünek kırılma, çatlağın oluşması ve büyümesinde önemli ölçüde kalıcı şekil değişiminin görüldüğü kırılma türüdür. Çatlak boşlukların oluşması ve birleşmesi ile meydana gelir ve yavaş ilerler. Kırılma yüzeyi mat ve lifli bir görünümündedir.

Gevrek kırılmada ise çatlak büyük bir hızla ilerler ve kalıcı şekil değişimi önemsiz düzeylerde olur. Ayrılmalar çok taneli bir yapıda her tanenin en düşük kohezyon dayanımlı kristallografik düzleminde oluşur ve kırılma yüzeyi parlak ve taneli bir görünümündedir. Gevrek kırılmanın diğer bir türü de taneler arası kırılmadır ve tane sınırlarının kırılğan bir yapıda olması halinde görülür.

Gevrek kırılma önceden farkına varılmasına imkân olmadan ve büyük bir hızla oluştuğundan en tehlikeli kırılma türüdür. Geçmişte bu nedenle ortaya çıkan hasarların çoğu bir facia ile sonuçlanmış, ancak o yıllarda bu olaylar mühendislik tasarım hatası olarak görülmüştür. Daha sonra malzemelerin gevrek kırılma davranışlarının pekiyi

bilinmediği fark edilerek, konuya büyük bir önem verilmiş ve Kırılma Mekaniği olarak adlandırılan yeni bir bilim dalı geliştirilmiştir [15].

Mühendislik yapılarında kullanılacak olan malzemelerin özelliklerini çok iyi bilmek gerekir. Bu özelliklerin en önemlilerinden biri de mekanik mukavemettir. Malzemelerin dayanımı, kullanıldıkları yapı birimi için yeterli olmalıdır. Fakat malzemelerde teorik olarak hesaplanan dayanım, pratikte elde edilememektedir. Bu da önemli bir sorun olan, malzemelerin akma yoluyla değil, kırılma diye bilinen gevrek davranış sonucu dayanımlarını yitirmelerinin bir sonucudur.

Mühendislik yapılarındaki çatlak veya çatlak gibi kusurların varlığı engellenemez. Mevcut enerji ve malzeme tasarrufu düşüncesi yapıların daha az güvenlik payı ve dolayısıyla kusurlara daha büyük tolerans ile tasarlanmış olmasını gerektiriyor. Bu nedenlerden dolayı, mühendisin çatlak yapısı ardında olan gücü ve etkiyi belirlemesi gereği ortaya çıkıyor. Bu şartlar altında, elemanın yapısal bütünlüğü için mühendis, çatlak veya çatlakların nasıl ve ne zaman daha da büyüyeceğini, ilerleyebileceğini ve parçanın bu şekilde hasara uğrayacağını bilmelidir. Bu soruları cevaplamaya yardımcı olan teknoloji Kırılma Mekaniğidir [16].

2.1.2. Kırılma Mekaniğinin Tarihi ve Gelişimi

Kırılma Mekaniği Bilimi, malzemede var olan, çentik, çatlak ve boşluk gibi gerilme yığılmasını artıran kusurları ve bunlara bağlı olarak meydana gelen hasarları inceler [17].

İlk olarak Galilei [18] tarafından, “niçin cisimler kırılır?”, sorusuna cevap aranmıştır. Galilei’nin bu düşünceleri aynı zamanda boyut etkisi teorisinin ilk adımlarıdır.

Coulomb 1776 yılında basınç altındaki kayaların kırılması konusunda yaptığı çalışmalarında malzeme kusurlarını dikkate almasından dolayı Kırılma Mekaniğine öncülük etmiştir [19]. 1913 yılında English, sonsuz bir levhada eliptik bir boşluk çevresindeki gerilme durumunu incelemiştir. English’in çalışmaları kırılma mekaniğine temel teşkil etmiştir [20].

Kırılmayla ilgili bir problemin ilk başarılı analizi ise 1920 yılında Griffith tarafından camlardaki gevrek çatlakların ilerleyişinin izlenmesiyle gerçekleştirilmiştir. Griffith, sistemin toplam enerjisindeki azalmayla önceden var olan bir çatlağın ilerlemeye başlayacağını formüle etmiştir. Griffith basit bir enerji dengesi öngörmüştür; gerilme altındaki bir sistemde çatlak ilerledikçe elastik şekil değiştirme enerjisinde bir azalma olur ki bu enerji de yeni çatlak yüzeylerinin oluşması için gerekli enerjidir. Bu teori, gevrek

katılarda teorik mukavemetin tahminine yaradığı gibi kırılma mukavemetiyle hata boyutu arasındaki ilişkiyi de verir [1].

Griffith yaklaşımı, 1944 de Zener ve Hollomon tarafından metalik malzemelerin gevrek kırılmasında uygulanmıştır [21].

Yeni bir kazaya yatkın yapıların devri, kaynaklı tasarımların ortaya çıkmasıyla başlamıştır. Özellikle de 2. Dünya Savaşı'nda müttefiklerin gemi ve tankerlerinde çok sayıda hasarlarla karşılaşmıştır. Üretilen 2700 müttefik gemisinden yaklaşık 400 tanesi hasara uğramış, hasara uğrayan gemilerden 20'ye yakını ortadan ikiye bölünürken 90 tanesi de ciddi bir biçimde zarar görmüştür. Bu hasarlar genellikle çok düşük gerilmeler altında ve hatta gemiler limanda demirlemişken oluştuğundan, bu konuda geniş araştırmalar yapılmış ve sonuç olarak kırılmaların gevrek kırılma olduğu ve bundan da malzemedeki hataların ve gerilme yığılmalarının sorumlu olduğu bulunmuştur. Ayrıca kullanılan çeliklerin gevrek kırılmaya, düşük sıcaklıklarda daha yatkın olduğu fark edilmiştir. Belirli bir geçiş sıcaklığının altında çelikler gevrek davranış göstermekte ve kırılma için gerekli enerji büyük ölçüde azalmaktadır [22].

1950'lerin ortalarında Irwin, kırılma mekaniğinde yeni bir çığır açmıştır. "Enerji yaklaşımı, gerilme yoğunluğu yaklaşımıyla eşdeğerdir". Buna göre, çatlak ucunda kritik bir gerilme dağılımına erişildiğinde kırılma oluşur. Böylece kritik gerilme yoğunluğu K_c veya enerji terimleriyle G_c kritik değeri, bir malzeme özelliğidir [23].

G ve K'nın eşdeğerliliği, Lineer Elastik Kırılma Mekaniğinin (LEKM) gelişmesine temel oluşturmuştur. Çünkü bir çatlak ucunun etrafındaki ve yakınındaki gerilme dağılımı durumu her zaman (tüm malzemeler için) aynıdır. Dolayısıyla, belirli standart numunelerle K_c 'i belirlemek için yapılan deneyler sonucunda malzemelerin yorulma çatlak ilerleyişi veya gerilmeli korozyon çatlaması gibi kritik-altı çatlamaya olan hassasiyetleri de bir dereceye kadar tahmin edebilir.

1960'lı yılların başında Irwin'in aksine Dugdale ve Barenblatt gibi bazı araştırmacılar, çatlağın ucundaki kırılma süreci bölgesindeki gerilme dağılımının, bir fonksiyon olduğunu kabul edip, matematiksel olarak probleme yaklaşmışlardır [24,25].

EPKM, Wells'in 1961 yılında çatlak açılması (COD) üzerine yaptığı çalışmalarla başlar. Daha sonra Billby, Cotrell, Swindon ve Dugdale, Barenblatt'ın teorisini ince elastik plastik levhalara uygulamışlar ve çatlak ucunda Çatlak Ucu Açılım Deplasmanı (CTOD) terimini ortaya atmışlardır [26].

Çatlak açılım deplasman metotlarından biride Rice tarafından geliştirilen J integrali yaklaşımıdır [27]. Ana prensip iki boyutlu bir çatlak durumu için çatlak çevreleyen bir yol boyunca hesaplanan şekil değiştirme enerjisinin yoğunluğunu bulmak üzere oluşturulmuştur. Green fonksiyonu (bu fonksiyon kapalı bir alanı, alanı çevreleyen eğri üzerinden giderek bulur.) ana prensiptir.

1970’li yıllardan sonra ise Hillerborg [28] ve Carpinteri’nin [29] yaptığı çalışmalar sonucu CTOD, kritik bir değeri olan w_c ’ye ulaştığında ise çatlak anı olarak ilerleyeceğini ve bunun bir malzeme sabiti olarak kullanılabileceğini ispatlamışlardır.

1980’li yıllardan itibaren bilgisayarların işlem yeteneklerinin gelişmesi ve dolayısıyla sonlu elemanlar yönteminin yaygın olarak kullanılmasıyla, lineer olmayan hesap yöntemleri kullanılarak kırılma mekaniği problemlerine yaklaşılmıştır. Bu gelişmeler, yeni metotların bulunmasına ve kırılma mekaniğinin ilerlemesine çok büyük katkıda bulunmuştur

Özet olarak, günümüzde teknolojinin hızla ilerlemesiyle malzemede var olan; çentik, çatlak, delik ve kılcal boşluk gibi kusurlar her geçen gün biraz daha giderilmektedir. Böylece malzeme kusurları azaldıkça dayanım artmakta ve daha sağlam yapılar inşa edilmektedir.

2.1.3. Lineer Elastik Kırılma Mekaniği (LEKM)

Malzeme içinde mikro çatlak ve benzeri kusurlar doğal olarak mevcut olmaktadır. Kırılma mekaniğinin incelenmesinde kullanılan ve malzemedeki tüm davranışların elastik sınırlar içinde kalması prensibinden hareketle geliştirilen analitik ifadelerin bütününe Lineer Elastik Kırılma Mekaniği (LEKM) denir. Bu metodun temel prensibi çatlak ucunda oluşan gerilmelerin parçaya uygulanan gerilmeye, çatlak uzunluğuna ve yönüne bağlı olarak ifade edilmesidir [30].

1913 yılında English, sonsuz bir levhada eliptik bir boşluk çevresindeki gerilme durumunu incelemiştir. English’in teorisi elastisite teorisi tabanlıdır [20]. 1920’li yıllarda Griffith, English’in teorisini daha da geliştirmiş ve LEKM’nin temellerini atmıştır. Griffith cam lifler üzerinde yapmış olduğu deneylerde, teorik mukavemetin, elastisite modülünün %10’u ($E/10$) civarında olduğunu ve malzemenin gerçek mukavemeti ile arasındaki bu uçurumun bünyesindeki kusurlardan kaynaklandığını tespit etmiştir [1]. Malzemeye uygulanan gerilmenin oldukça düşük olmasına rağmen, gerilme yığılması nedeni ile teorik

kohezif dayanıma erişilebilir. Nitekim Griffith 'in cam liflerin dayanımlarının, normal plaka camlarına nazaran çok mukavemetli olduğunu ortaya koyması bunun açık ispatıdır.

$$\sigma^2 \geq \frac{2\gamma E}{\pi a} \quad (2.1)$$

İfade 2.1' de γ yüzey enerjisi, E elastisite modülü, a çatlak boyu ve σ levhaya uygulanan gerilmedir. Griffith kırılmaya devrine göre çok ilgi gören bir konu olan enerji ile yaklaşmıştır, gerilme altındaki bir sistemde çatlak ilerledikçe elastik şekil değiştirme enerjisinde bir azalma olur, bu da yeni çatlak yüzeylerinin oluşması için gerekli enerjidir. Bu teori gevrek katılarda teorik dayanımın tahminine yaradığı gibi kırılma mukavemetiyle kusur boyutu arasındaki ilişkiyi de verir.

Griffith yaklaşımı, 1944 de Zener ve Hollomon tarafından metalik malzemelerin gevrek kırılmasına da uygulanmıştır [21].

Kırılma mekaniğinde kırılma ile ilgili parametreler kırılma tokluğu ve ya gerilme şiddet faktörü olarak adlandırılır. "K" sembolü ile gösterilir. K, çatlak civarında gerilme alanını belirleyen bir parametre olup, bu faktör malzemenin geometrik hali, yüklenme şekli, çatlağın yerine bağlıdır. "K", yalnız gerilme durumu ve çatlağın geometrisiyle ilgili bir parametre olup malzemenin özelliklerine bağlı değildir. Hâlbuki kırılma tokluğu " K_c ", malzeme özelliğiyle ilgili bir parametredir. Kırılma tokluğu " K_c " özelliğini belirlemek için gerilme şiddet faktörü "K" ölçülür. $K_c = K$ olduğunda çatlak ilerler ve kırılma olur. Kırılma tokluğu K_c numunenin kalınlığına bağlı olarak değişir ve numune kalınlığı arttıkça belli bir değere kadar azalır, bundan sonra kalınlık etkisi olmaz. Numunenin kalınlığının limit bir değerinden sonra, numune yüzeyinin etkisi kalmamakta ve esasında düzlem şekil değişimi durumu sağlanmaktadır. Düzlem şekil değiştirme durumu en şiddetli ve kritik gerilme durumunu gösterir ki, bu durumda K_{Ic} değeri düzlem gerilme durumundaki değerden küçüktür. Düzlem gerilme durumunda numunenin yüzeylerine, düzlem şekil değişimi durumunda ise numunenin merkezine gerilme uygulanmaktadır [31].


Gevrek bir malzemede çatlak ucunda yüksek bir gerilme yoğunluğu oluşur. Çatlak veya kusur ucunda oluşan bu yüksek gerilme yığılması nedeniyle, malzemede gerilme tüm kesitte üniform olarak yayılamadan malzemenin çekme dayanımı aşılır. Hemen hemen tüm malzemeler küçük çatlaklar ve bazı kusurlar içermektedir. Malzemelerde yüklemekten bağımsız olarak önceden var olan bu çatlak ve kusurların kenarlarında oluşan gerilme

yığılmalarından dolayı bu malzemelerin çekme dayanımı, teorik olarak hesaplanan çekme dayanımından daha düşüktür. Gerilme yığılması faktörü, gevrek kırılmayı tanımlayan bir kırılma kriteri olarak görev yapar [32]. Böylece, lineer elastik kırılma mekaniğine göre, gevrek malzemelerin kırılma sürecinin tanımlanması için sadece bir parametreye, I indisi açılma modunu göstermek üzere gerilme şiddet çarpanına (K_{Ic}) ihtiyaç vardır [33].

Bir malzemenin kırılma tokluğu malzemede çatlak mevcutken yük taşıyabilme kapasitesi veya plastik olarak deforme olabilmesi olarak tanımlanabilir. Malzemede tokluğu, düzlem gerilme şartlarında (K_c) kritik gerilme yoğunluğu, düzlem şekil değiştirme şartlarında (K_{Ic}) kritik gerilme şiddet faktörü ile ifade edilebilir. Bu davranışlar, Lineer Elastik Kırılma Mekaniğinde (LEKM) geçerlidir [116].

1950'lerin ortalarında Irwin [23] kırılma mekaniğinde yeni bir dönem başlatmıştır. Griffith'in teorisi cam gibi tam gevrek malzemelerde çatlağın yayılması için gerekli olan gerilmenin değerini vermektedir. Çatlağın yayılmadan öncesi veya sonrası hakkındaki herhangi bir bilgiyi içermemektedir. Irwin, seramik lifler üzerinde yapmış olduğu deneylerde teorik mukavemetin E/10 civarında olmadığını görmüş ve teoriyi metalleri de (plastik şekil değiştirme yeteneğine sahip malzemeler) içine alarak genişletmiştir. Daha sonra sırasıyla açılma (çekme), kayma ve burulma durumlarına karşılık gelen üç yükleme durumu Şekil 2.1.'deki mod I, mod II, mod III, genel kırılma modlarını ve bunların kombinasyonundan oluşan karışık modun kanunlarını ve K adı verilen gerilme şiddet çarpanını ortaya koymuştur [34].

$$\begin{aligned} K_I &= \sigma \sqrt{\pi a} \\ K_{II} &= \tau \sqrt{\pi a} \\ K_{III} &= \tau \sqrt{\pi a} \end{aligned} \tag{2.2}$$



Şekil 2.1. Kırılma modları

Denklemlerde (2.2) σ , malzemeye uygulanan çekme gerilmesi τ , kayma gerilmesi ve a , merkezi çatlaklı yapılarda yarı çatlak uzunluğu, sınır çatlaklı durumda tam çatlak uzunluğudur [31].

K , bir malzeme sabiti olmayıp her malzeme ve aynı geometri ve de yükleme durumunda sabit olarak alınan bir değerdir. Belirli bir kritik değerde yani " K_c " değerine ulaştığında her malzeme için farklı bir değer alır ve kırılma tokluğu diye ifade edilir [35]. Mod I durumu için b numune genişliği, d numune karakteristiği (tez çalışmasında bu ifade beton numunelerde kesit yüksekliği, betonarme numunelerde faydalı yükseklik olarak alınacaktır) ve P_u kırılma yükü olarak alınırsa, nominal dayanım $\sigma_N = P_u / (b \times d)$ olmak üzere kritik gerilme şiddet çarpanının ifadesi;

$$K_{Ic} = \sigma_N \sqrt{\pi a} f\left(\frac{a}{d}\right) \quad (2.3)$$


şeklindedir. Denklem 2.3'de σ_N : Göçme anındaki nominal gerilme (MPa), $f\left(\frac{a}{d}\right)$: numune boyutları ile ilgili geometrik faktördür. Ancak, çatlağın başlangıcı ve yayılma hızı mühendislik açısından çok daha önemli olduğundan, Irwin, G_c çatlak yayılma hızı kavramını ortaya atmış ve K_c ile arasındaki bağıntıyı formül 2.4'de şu şekilde vermiştir [35]:

$$G_c = \frac{K_c^2}{E} \quad (2.4)$$

Irwin (1958), çatlakın hemen ucunda kırılma süreci bölgesi adı verilen bölgede gerilme dağılımının sabit ve değerinin malzemenin akma dayanımına eşit olduğunu kabul etmiştir. Şekil 2. 2.'de kırılma süreci bölgesi tanımlanmıştır. Kırılma süreci bölgesinin uzunluğunu ise formül 2.5'de şu şekilde ifade etmiştir:

$$r_p = \frac{1}{\pi} \frac{K_{Ic}^2}{f_t^2} = \frac{1}{\pi} \frac{E G_c}{f_t^2} \quad (2.5)$$

burada f_t , malzemenin çekme dayanımı E, elastisite modülüdür.



Şekil 2.2. Kırılma süreci bölgesi

Şekil 2. 2'de r_y , kırılma süreci bölgesi uzunluğu d, levhanın genişliği a, çentik boyunu ifade etmektedir .

G ve K'nın eşdeğerliliği Lineer Elastik Kırılma Mekaniğine (LEKM) temel oluşturmuştur. Çünkü tüm malzemeler için, bir çatlak ağzının etrafındaki ve yakınındaki gerilme dağılımı durumu her zaman aynıdır. Dolayısıyla K_c 'nin bilinmesiyle gerçek

yapılarda ve belirli şartlar altında malzemede hangi hatalara izin verilebileceği saptanabilir. Ayrıca bu yaklaşımla yapılan deneyler sonucunda malzemelerin yorulma, çatlak ilerleyişi veya gerilmeli korozyon çatlama gibi hassasiyetleri de bir dereceye kadar tahmin edilebilir.[36]

İlk olarak Griffith [1] tarafından temeli atılan Lineer Elastik Kırılma Mekanik (LEKM) teorisi, 1960'lı yılların başında Kaplan [2] tarafından betona uygulanmıştır. Ancak daha sonra yapılan deneysel çalışmalar, LEKM kanunlarının beton için yetersiz olduğunu göstermiştir [3]. Bu amaçla birçok araştırmacı tarafından teknolojik ve nümerik alanlardaki gelişmelere paralel olarak, lineer olmayan kırılma mekanik yaklaşımları geliştirilmiştir [4-9].

2.1.4. Lineer Olmayan Elastik Kırılma Mekanik

Lineer elastik kırılma mekanikine göre, bir çatlak ucundaki gerilme teorik olarak sonsuza gider. Oysaki gerçek malzeme için bu doğru değildir. Gerçek bir malzemede çatlak önünde elastik olmayan bir bölge oluşur. Bilindiği gibi beton oldukça heterojen bir yapıdadır. Betonda çatlak önünde oluşan kırılma süreci bölgesinde mikro çatlaklar, çatlak sapması, agregaların çatlak köprüleşmesi, çatlak yüzeyleri arası sürtünme, çatlağın boşluğa denk gelerek uç körelmesi ve çatlak ikizlenmesi gibi toklaşma mekanizmaları nedeniyle yeni çatlaklar oluşması için daha fazla enerji harcanması gerekmektedir. Bu toklaşma mekanizmalarının varlığı lineer elastik kırılma mekanikinin betona uygulanmasını sınırlamaktadır [23].

Betonun lineer olmayan kırılma davranışını karakterize etmek için önerilen metotlar, Kohezif Çatlak Modelleri ve Efektif Çatlak Modelleri olarak iki kategoride sınıflandırılmaktadır. Kohezif çatlak modelleri içerisinde Hillerborg [4] tarafından önerilen kırılma-ışık-enerjisi (KİE) yaklaşımı ve Bazant ve Pfeiffer [37] tarafından önerilen Boyut Etkisi Modeli (BEM) yer almaktadır. Efektif Çatlak Modelleri sınıfında ise Jenq ve Shah [6] tarafından önerilen İki Parametrelili Model (İPM) ve Efektif Çatlak Modeli (EÇM) [7] gibi iki model yaygın olarak kullanılmaktadır [35].

2.2. Betonun Kırılma Mekanikği

2.2.1. Giriş

Yapıların inşasında birçok çeşit malzeme kullanılmaktadır. Beton bunlar içerisinde en çok kullanılan yapı malzemesidir. Bu nedenle betonun mekanik davranışının tam olarak anlaşılmasının önemi her geçen gün artmaktadır. [38].

Betonun kırılma mekanikği depreme dayanıklı binalar, savunma amaçlı yapılar, reaktörler, iklim ve çevre koşullarının etkisinde yıpranmaya maruz binalar gibi ekonomik açıdan maliyeti yüksek yapılar için oldukça büyük bir öneme sahiptir. Bu tür yapılarda göçmenin nasıl, nereden ve hangi koşullarda oluşacağı, var olan bir çatlağın hangi şartlar altında kararlı veya kararsız bir şekilde ilerleyeceği kırılma mekanikği bilim dalının konularıdır. Bu amaçla Lineer Elastik Kırılma Mekanikğinin (LEKM) betona ilk uygulaması 1960'lı yıllarda yapılmasına rağmen betonun yarı gevrek ve heterojen bir malzeme olması nedeniyle betonun kırılma parametrelerinin LEKM ile elde edilemeyeceği görülmüştür. Bu nedenle, daha sonraki yıllarda LEKM modifiye edilerek Nonlineer Kırılma Mekanikği modelleri oluşturulmuştur.

Araştırmacılar beton, çelik, seramik gibi malzemelerin kırılma davranışlarını daha iyi modelleyebilmek için kırılma mekanikği kuramlarını oluşturmuşlardır. Kırılma mekanikği iki temel kriteri dikkate alan bir davranış kuramıdır. Malzeme dayanımını enerji ve dayanım kriteri ile birleştiren ve çatlamayı bütün yapı boyunca ilerleyen bir davranış olarak gören bir kuramdır.

Çelik, cam ve seramik gibi homojen malzemelere uygulaması çok daha çabuk gerçekleşmiş olan kırılma mekanikğinin beton ve betonarmeye uygulaması bu malzemenin homojen olmaması nedeniyle zor olmaktadır. Üretildiğinde de çatlaklı olan betonun davranışını geleneksel kuramlarla doğru olarak açıklamak olası görünmemektedir. Ancak çatlak ilerlemesi için gereken enerji ve yapının şekli ile davranışın daha doğru açıklanabildiği araştırmacılar tarafından deneysel verilere dayanarak kanıtlanmıştır. Son on yılda betonun kırılma mekanikği konusunda yapılan araştırmalar çelikten çok betonun kırılmaya yol açtığı tüm elemanların göçme yükünde boyut etkisi göstermelerinin gerektiğini ortaya koymuştur. Bu yalnız betonun çekme gerilmelerini taşıyamadığı için

oluşan kırılmalarda değil betonun basınç gerilmelerini taşıyamadığı için meydana gelen kırılmalar için de geçerlidir [39-40].

Yapılan deneysel çalışmalar, betonun kırılma parametreleri üzerine betonun basınç mukavemeti, su/çimento oranı, maksimum agrega çapı ve agrega tipinin etkili olduğunu göstermektedir [13-14].

Betonun malzeme özellikleri (agrega hacmi, agrega boyut dağılımı, su/ çimento oranı gibi), çatlak oluşması ve yayılması üzerinde önemli etkilere sahiptir ve beton mekanik davranışı kırılma mekaniği ile incelenebilir. Örneğin, yüksek mukavemetli beton daha kırılğan ve gevrek bir malzemedir. Lif katkılı betonlarda çatlak oluştuktan sonra lifsiz betonlara kıyasla toklukta artış gözlenmektedir. Laboratuvar numunesi boyutlarına sahip bir betonun kırılması ile gerçek boyutlarda bir beton elemanın kırılması da birbirinden farklıdır. Bu nedenlerle, farklı malzeme özelliklerine ve boyutlara sahip betonların kırılması, kırılma mekaniği parametreleri ile incelenerek modelleme yapılabilir.

Beton gibi yarı-gevrek malzemelerin kırılma mekaniğinde, mod I çatlak yayılması durumu için serbest kalan şekil değiştirme enerjisi ifade (2.6) ile tanımlanabilir [41].


$$G_I = \frac{K_I^2}{E} + \int_0^{CTOD} \sigma(w)dw \quad (2.6)$$

burada K_I mod I çatlağı için gerilme şiddet çarpanı, w çatlak açılımı deplasmanı, $\sigma(w)$ w 'ye bağlı olarak değişen çatlak yüzeyine dik basınç gerilmesi ve CTOD çatlak ucu açılımı deplasmanı değeridir. İlk uygulamalarda kırılma süreci bölgesinin (KSB) kohezif doğasından dolayı, Şekil 2.3'te görüldüğü gibi uygulanan dış yükten oluşan toplam enerji, çatlak ucunda karşılıklı basınç gerilmeleriyle dengelenmeye çalışılmıştır [9]. Bu sebeple kohezif çatlak yaklaşımlarında, ifade (2.6)'da $K_I = 0$ olduğundan, sadece ikinci terim kullanılarak beton modellenmiştir. Diğer taraftan 1980'lerin ikinci yarısından sonra önerilen diğer lineer olmayan kırılma mekaniği modellerinde, Kırılma Süreci Bölgesi (KSB) Irwin'in plastik bölge düzeltmesi kavramına benzer olarak bir efektif çatlak uzunluğu tanımlanarak beton modellenmeye çalışılmıştır [6,8]. Bu sebeple Şekil 2.3'te görüldüğü gibi, eşdeğer elastik çatlak yaklaşımlarında $\sigma(w) = 0$ olacağından ifade (2.6)'da sadece ilk terim kullanılmaktadır. Ancak efektif çatlak uzunluğu numune boyut ve geometrisine bağlı olarak değiştiğinden, bu tür modeller en az iki kırılma parametresi ile beton yapıda göçmeyi modellemektedirler.

Herhangi bir kırılma modelindeki temel amaç ifade (2.7) de tanımlanan, pik yükte kritik çatlak uzama miktarını (kırılma süreci bölgesinin uzunluğunu) belirlemektir.

$$\Delta a = a_c - a_0 \quad (2.7)$$

Burada, a_c pik yükteki kritik çatlak boyu ve a_0 başlangıç çatlak boyudur. Bununla beraber a_c kritik çatlak boyu numune boyutunun artmasıyla azaldığından dolayı, yapının boyutuna bağlıdır. Bu sebeple, lineer olamayan kırılma mekaniği yaklaşımları, betonun kırılması için en az iki parametrenin kullanılmasını önermektedir [12].



Şekil 2.3. Betonda kullanılan lineer olamayan modeller [12].

Betonda gerilme, kırılma dayanımının %30'una ulaştığında önce iri agrega harç ara yüzeyindeki çatlaklar en büyük çekme gerilmesine dik olarak çoğalmaya ve büyümeye başlar. Basınç yükü altında da önce ara yüz çatlakları büyür ve hamur içinde yük doğrultusunda çatlaklar oluşturur. Bu çatlaklar birleşerek kritik boya ulaşırlar ve hızlı yayılma ile yüke paralel veya eğik olarak cismi parçalarlar. Çekmeye oranla basınçta daha çok çatlak oluşması ve daha yavaş çatlak yayılması görülür. Bununla beraber eksenel yüke ek olarak yanal basınç uygulandığında hamur içindeki çekme gerilmelerinin azalması ve ara yüzeyde sürtünmenin artması dolayısıyla dayanım artışı gözlenmektedir [42].

2.2.2. Betonun Kırılma Mekanikinin Tarihsel Süreci

Kırılma Mekanikği önceleri sadece gevrek ve homojen bir malzeme olan camda ve yine bazı homojen metallerde kullanılmıştır. Daha sonraki yıllarda bunun beton gibi yarı gevrek ve heterojen bir malzemede kullanılabilirliğı araştırılmıştır. Bununla ilgili çalışmalar ilk kez Kaplan ile başladı [2]. Kaplan, betonu LEKM (Lineer Elastik Kırılma Mekanikği) Prensiplerini kullanarak incelemiştir. Daha sonra yapılan çalışmalarda, betonun kırılmasının tek bir parametre ile ifade edilemeyeceğı anlaşılmıştır. Bu sebeple betonun kırılmasının karakterize edilmesi için, Lineer Olmayan Kırılma Mekanikği Yaklaşımları geliştirilmiştir

Kaplan, betondan yaptığı, farklı boyutlarda ve değışik çentik boylarına sahip olan kırıřlara üç ve dört noktalı eğilme deneyi yaparak, G_c değıerlerini hesaplamıştır. Hesaplarında deneysel ve analitik yöntemler kullanılmıştır. Kaplan çalışmalarının sonucunda Griffith [1] teorisinin betona uygulanabileceğini savunmuştur.

Glucklich [43], Griffith'in teorisinin, homojen bir malzeme için geçerli olduğunu, beton gibi heterojen bir malzemeye değıştirilerek uygulanması gerektiğini savunmuştur.

Kaplan ve Glucklich'in çalışmalarından sonraki yıllarda kırılma mekanikğinin betona uygulanması ilgi kazanmıştır. Çeřitli araştırmacılar Kaplan'ın çalışmasına benzer olarak kırılma mekanikği parametrelerini belirlemişlerdir. Kullanılan numune tiplerine ve deney metoduna bağılı olarak analitik bağıntılar ile parametrelerin hesaplanma yöntemleri farklılık göstermiş, bu arada su/çimento oranı, agrega büyüklüğü ve miktarı gibi beton değıışkenlerinin etkileri de araştırılmıştır.


Romualdi ve Baston [44], Zaitsev [45], Swamy [46] tarafından da çeřitli araştırmalar yapılmıştır. Bu araştırmalarda kritik kırılma parametresi olarak K_{Ic} yi (veya G_{Ic}) kullanmışlardır. Bu parametreleri çentikli paneller ve kırıřlar üzerinde yapmış oldukları deneylerde tespit etmişlerdir. Bu araştırmalar ve daha sonraki, Brown [47], Shah ve McGarry [48], Walsh [49], Higgins ve Bailey [50], Mindess ve Nadeau [51], Walsh [52], Gjorvvd.[17], Rossi vd. [54] tarafından yapılan araştırmalarda deney numunesinin boyutları, şekli ve başlangıçtaki çentik uzunluğuna bağılı olarak K_{Ic} değıerinin sürekli olarak değıışmesinden, bu sabit değıerin beton gibi heterojen bir malzeme için tutarlı bir malzeme sabiti olmadığı anlaşılmıştır. Ayrıca numune kalınlığı ve çentik genişliğinin, K_{Ic} üzerine etkisinin çok az olduğı tespit edilmiştir.

Ancak maksimum agregâ apının numune karakteristik boyutuna oranının kk olduėu durumlarda (~ 0.01) davranışın LEKM e daha ok yaklaştığını ve K_{Ic} 'nin sabit bir deėer etrafında ok kk salınımlar yaptığı Ohgishi vd. [54] ve Tian vd. [55] tarafından tespit edilmiştir.

Beton zerinde kırılma mekaniėi ile ilgili alıřmalar aynı noktada birleşmiştir. Beton gibi heterojen bir malzemeyi tek bir parametre ile ifade etmek mmkn deėildir. alıřmalar bu noktadan itibaren lineer olmayan metotların gelişmesi şeklinde devam etmiştir.

2.2.3. Betonda Kırılma Sreci Blgesi

Son zamanlarda beton malzemelerinde kırılma sreci blgesi iin birok alıřma yapıldı ve kırılma karakterlerinin beton yapılar zerindeki etkisi modellenebildi. Deneysel arařtırmalar gsterdi ki, beton yapıların kırılma sreci  farklı evre iermektedir; atlak bařlangıcı, kararlı atlak yayılması ve kararsız atlak yayılması. Genellikle tm blge, atlak bařlangıcı ve kararsız atlak yayılmasını kırılma sreci blgesi olarak adlandırır. Bu  durum betonun gerilme řekil deėiřtirme davranışı gz nne alınarak řekil 2.4'te gsterilmiştir. atlaėın yayılmasını ve kırılma sreci blgesinin etkisini yansıtmasını tahmin etmek amacıyla beton malzemelerin kırılma karakterleri zerinde birok model; Fiktif atlak Modeli (FCM) [9], atlak Bant Modeli (BM) [5], İki Parametrelili Kırılma Modeli (İPM) [8], Efektif atlak Modeli (EM) [56,57] ve Boyut Etkisi Modeli (BEM) [58] nerilmiştir. Bu modellerde, beton malzemelerin atlama zellikleri tanımlanarak farklı malzeme parametreleri tanımlanmıştır. Benzer olarak kırılma parametrelerine iliřkin test metotları saptanarak, Fiktif atlak Modeli (FM) G_F (Gerilme Tokluėu), İki Parametrelili Kırılma Modeli (İPM) K_{Ic}^S (kritik gerilme řiddet arpanı) ve $CTOD_c$ (kritik atlak ucu aılımı), Boyut Etkisi Modeli (BEM) G_f (Gerilme tokluėu) ve c_f (Etkin kırılma geniřliėi) RILEM tarafından nerilmiştir [10,59-61].




Betonun kırılma süreci bölgesi onun lineer olmayan davranışının açıklanmasında en önemli kavramdır. Şekil 2.5.a da çekmeye maruz çentikli bir numunenin yük-deformasyon eğrisi görülmektedir. Burada AB pik yük öncesi lineer olmayan bölge, BC mikro çatlaklar sonucu oluşan çekmede yumuşama bölgesini temsil etmektedir. CD kısmı ise bu eğrinin kuyruk kısmı olup agrega kilitlenmesi ve yüzeyler arası sürtünmeden dolayı meydana gelen bölgedir.

Meydana gelen şekil değiştirmeler, tepe yükü civarında (B noktası) kırılmanın gerçekleşeceği düzlemde birikmeye başlar (şekil değiştirme yerelleşmesi). Çatlaklar ilerlemeye devam ettikçe şekil değiştirmeler artar ve yük taşıma kapasitesi azalır. Böylece


çatlaklar adım adım ilerleyerek betonun yük taşıma kapasitesinin aniden sıfıra düşmesini engeller ve tepe yükü sonrasında betona tokluk kazandırır. B-C noktaları arasında kalan bu bölgede şekil değiştirme yumuşaması görülür. Bu nedenle beton, yarı gevrek bir malzeme kabul edilir.

Irwin, (1958) metalik ve seramik malzemeler için tanımladığı kırılma süreci bölgesi beton için eğrinin BCD kısmında gelişir (Şekil 2.5.b). Bu zon ilk önce makro çatlağın yanındaki agregayı saran matris içerisindeki önemsiz mikro çatlaklarla başlar (Şekil 2.6.a). Daha sonra agrega çevresindeki zayıf bölgede büyük çatlaklar oluşur (Şekil 2.6.b), bu çatlaklar matris içerisindeki mikro çatlaklarla birleşerek makro çatlağa erişir (Şekil 2.6.c) ve sonunda bu çatlaklar numune uzayı içerisinde birbirini keserek ve köprüler kurarak numuneyi parçalarlar (Şekil 2.6.d) [72].


Bununla beraber kırılma süreci bölgesinin uzunluğu malzemenin granüler yapısı ile yakından ilgilidir. Örneğin cam gibi tam gevrek bir malzemede 10^{-6} mm (Bache, 1986) [63] olan bu zon normal beton için 200-500 mm (Hillerborg, 1983) [64] ve $d_a = 38$ mm olan baraj betonlarında 700 mm (Brühwiller vd., 1991) [65] mertebesinde olmaktadır. Bu değişim çeşitli malzeme sınıfları için Şekil 2.7. de görülmektedir (ACI Report 446.1R.91) [32].



Şekil 2.5. a) Çekmeye maruz bir numunenin yük-deformasyon diyagramı. b) Kırılma süreci bölgesi [72].



Şekil 2.6. Kırılma süreci bölgesinin gelişimi [72].



Şekil 2.7. Değişik malzeme sınıfları için L:lineer, N:non-lineer ve K:kırılma süreci bölgeleri


Gevrek malzemelerde çatlakın ilerlemesini ve kırılmayı tanımlamak için sadece bir malzeme parametresi, kırılma tokluğu (K_I^c) yeterlidir. Malzemenin kırılma tokluğu önceden çatlak içeren farklı geometrilere sahip numunelerle deneysel olarak hesaplanabilmektedir. Örneğin, çentikli kiriş numuneler üzerinde uygulanan üç noktalı eğilme deneyinde çatlak yayılmaya başlayıncaya kadar kiriş numuneye yük uygulanmakta ve maksimum yük elde edildikten sonra kullanılan numunenin boyutlarına ve yükleme durumuna bağlı olarak K_I^c hesaplanmaktadır [66]. LEKM, sertleşmiş çimento hamuru gibi gevrek malzemelere uygulanabilmektedir [62].

2.2.4. Çatlak Yayılmasını Önleyici Faktörler


Metalik bir malzemede kırılma öncesinde akma oluşacağı için çatlak ucunda meydana gelen gerilme artışı sonsuza gitmez ve akmanın görüldüğü plastik bir bölge oluşur (Şekil 2.8.a.). Beton gibi yarı gevrek bir malzemede de çatlak ucunda önemli oranda kalıcı şekil değiştirmeler meydana gelir. Oluşan gerilmelerin ve şekil değiştirmelerin orantılı olmadığı bu bölgeye Kırılma Süreci Bölgesi (KSB) adı verilir [116].

Meydana gelen şekil değiştirmeler ve mikro çatlaklar enerji yutar ve çatlak ucunda meydana gelen gerilme azalarak sonsuza gitmesi engellenir (Şekil 2.8.b.). Betonda meydana gelen kırılma süreci bölgesinin büyüklüğünden dolayı LEKM' in uygulanamayacağı birçok araştırmacı tarafından ortaya konmuştur [67]. Böyle bir bölgenin varlığı betonda meydana gelen toklaşma mekanizmalarına bağlıdır. Agregalar, boşluk ve mikro çatlaklar içeren bir malzeme olan betonda, çatlak ilerleyişi bir takım mekanizmalar tarafından engellenir ve betonda tokluk artışına neden olur (Şekil 2.9.).

Çatlak ucundaki agregaların çatlak ilerlemesini engelleyerek çatlak kalkanı görevini yapması, çatlağın agregalara rast gelerek yön değiştirmesi, agregaların birbirlerine sürtünerek çatlağın ilerlemesini engellemesi, agregaların çatlağın bir tarafından diğer tarafına yük aktarımında bulunması, çatlak ucuna rastgelen boşlukların çatlak ucu keskinliğini azaltması veya çatlağın dallanmasına neden olması gibi mekanizmalar betonda tokluk artışına neden olur.



Şekil 2.8. Sünek ve Yarı gevrek malzemede çatlak ucunda meydana gelen durumlar



Şekil 2.9. Betonda tokluk artışına neden olan mekanizmalar

Birçok araştırmacı betonda çatlak ucunda meydana gelen ve enerji harcanmasına neden olan bu kırılma süreci bölgesi ile ilgili incelemelerde bulunmuşlardır. Bu bölgenin boyutları betonun türüne ve beton yapının boyutlarına bağlıdır. Bu bölgenin uzunluğu çimento hamurunda 5-15 mm, harçta 100-200 mm, yüksek dayanımlı betonda 150-300 mm, normal dayanımlı betonda 200-500 mm ve baraj betonu gibi bir kütle betonda 700 mm civarındadır [66]. Bu tür mekanizmalar nedeniyle betonun kırılması tek bir parametre ile belirlenemez. Dolayısıyla LEKM' in bir çatlağın ilerlemesi için ortaya koyduğu çatlak ucundaki gerilme yığılmalarını ifade eden kırılma tokluğu (gerilme şiddet çarpanının kritik değeri) parametresi, betonda bir çatlağın hangi şartlar altında ilerleyeceğinin tahmini konusunda yetersiz kalmaktadır [62].

Çatlağın uzamasındaki enerji dış yüklerin, yaptığı işten veya betonda depo edilen gerinim enerjisi değişiminden kaynaklanır. Bu enerji kavramından hareketle beton içerisinde çatlağın yayılmasını engelleyen en önemli etken agregadır. Zira matris içerisinde ilerleyen çatlak bir agregaya ile karşılaşır minimum enerji prensibine göre ya agregaya içerisinden yada agreganın çevresinden ilerleyecektir. Bu durum enerji gereksinimini artırır. Öte yandan hidratasyona uğramamış çimento parçacıkları agregaya gibi davranırlar [68].

Çatlağın ilerlemesine engel olan bir diğer etken ise çatlak ucunda yeni mikro çatlakların oluşmasıdır. Tek bir çatlağın yerine, çatlaklar birbirlerine gerilme transferi yaptığından, bu durum yeni yüzey oluşumunun yanı sıra enerji gereksinimini de artırır.

Daha sonra bu yeni mikro çatlaklar birleşerek makro çatlaklar haline gelirler ve numuneyi boydan boya kat ederler. Yukarıdaki etkenlerin dışında, beton içerisinde bulunan hava boşlukları ve gözenekler çatlak ucunda eğrilik yarıçapını arttırdığından dallanmalara sebep olurlar ve bu yüzden çatlağı engelleyici unsurlardandır [69].

2.3. Efektif Çatlak Modelleri

2.3.1. Efektif Çatlak Modeli (EÇM)


Betonun kırılmasında efektif çatlak modeli, iki parametrelili modelin prensiplerine benzer olarak Nallathambi ve Karihaloo [7] tarafından geliştirilmiştir. Ancak efektif çatlak uzunluğu a_e yükleme-boşaltma eğrisindeki komplianstan hesaplanamaz. Şekil 2.10'da görüldüğü gibi, belirli bir a_0 başlangıç çatlak uzunluğuna sahip numunenin pik yüke karşılık gelen sekant modülü, farklı bir a_0 başlangıç çatlak uzunluklu kirişin dinamik modülüne eşdeğer olduğu duruma karşılık gelen a_0 başlangıç çatlak uzunluğunun değeri efektif çatlak uzunluğu olarak kabul edilir. Burada efektif çatlak uzunluğuna karşılık gelen K_{Ic}^e 'in kritik değeri esas alınır ise modelin iki parametrelili olduğu ortaya çıkar.

$$K_I = K_{Ic}^e, \quad \alpha = \alpha_e \quad (2.8)$$

buradan boyutsuz efektif çatlak uzunluğunun ifadesi:

$$\frac{\alpha_e}{d} = \gamma_1 \left(\frac{\sigma_N}{E} \right)^{\gamma_2} \left(\frac{\alpha_0}{d} \right)^{\gamma_3} \left(1 + \frac{d_\alpha}{d} \right)^{\gamma_4} \quad (2.9)$$

Burada $\gamma_1 = 0.088 \pm 0.004$, $\gamma_2 = -0.208 \pm 0.010$, $\gamma_3 = 0.451 \pm 0.013$ ve $\gamma_4 = 1.653 \pm 0.109$ 'dur



Şekil 2.10. Efektif çatlak modeli

Mevcut öneride, yarı statik yükleme koşulları altında üç noktalı eğilmede sınır çentikli kirişlerin testinin deneysel sonuçlarından kritik gerilme şiddet faktörü (K_{Ic}^e) belirlemek için direk yöntem ileri sürülmektedir. Bu öneriye göre hesaplanan kırılma parametresi K_{Ic}^e 'in numune boyutundan bağımsızdır.

Test numunelerinde örnek boyut aralıkları önerilmektedir. Kullanılan maksimum agrega boyutu 5-25 mm aralığında olabilir. Örneğin bir 20 mm maksimum agrega boyutu karışımı için numune derinliği (d) çatlama mesafesi (a) boyutu en az 100 mm. Genişliği 40 ila 100 mm arasında olabilir ve yükleme mesafe/derinlik oranı (S/d) 4 ila 8 arasında olabilir. Dış/derinlik oranı 0.2 ila 0.6 arasında olabilir fakat 0.3 veya 0.4 tercih edilir.

Malzeme testlerinin her tipi için en az dört numune tavsiye edilir. Kesilen veya önceden dökülen çentik (İyi yağlanmış takoz kullanılarak) genişliğinin 3 mm den daha büyük olmaması gerekir. Döküm işleminden sonra, numuneler ıslak çuval bezi ile örtülmelidir veya % 100 bağıl nem ile kür odasında muhafaza edilmelidir ve ilk 24 saat için sıcaklık $23 \pm 2^\circ\text{C}$ olmalıdır. 2. Gün tüm numunelerin kalıpları kaldırılır ve test etmeden yaklaşık 1 saat öncesine kadar kür odasına geçirilir. Örnekler test edilmeden önce geometrisi ölçülmelidir. Malzeme özelliklerinin hesaplanması için öncelikle şartname gereksinimleri ile ilgili olarak silindir numuneler test edilerek karışımın E modülü belirlenir [58].

2.3.1.1. Efektif Kritik Çatlak Uzunluğu (ae)

a_0/d oranlarının çeşitleri için P_i , P_{max} ve orta açıklık sehimlerine uygun gelen δ_i , δ_p değerleri okunur. Aşağıdaki denklemden numunenin E si belirlenir;

$$E = \frac{P_i}{4b\delta_i} \left(\frac{S}{d} \right)^3 \left[1 + \frac{5wS}{8P_i} + \left(\frac{d}{S} \right)^2 \left\{ 2.70 + 1.35 \frac{wS}{P_i} \right\} - 0.84 \left(\frac{d}{S} \right)^3 \right] + \frac{9}{2} \frac{P_i}{b\delta_i} \left(1 + \frac{wS}{2P_i} \right) \left(\frac{S}{d} \right)^2 F_2(\alpha_0) \quad (2.10)$$

Burada w kirişin öz ağırlığıdır ve

$$F_2(\alpha_0) = \int_0^{\alpha_0} \beta F_1^2(\beta) d\beta, \quad (2.11)$$

$\alpha_0 = a_0/d$ ile ve $S/d=4$ için,

$$F_1(\beta) = \frac{1.99 - \beta(1-\beta)(2.15 - 3.93\beta + 2.70\beta^2)}{(1+2\beta)(1-\beta)^{3/2}} \quad (2.12)$$

Bu oranlar dışında;

$$F_1(\beta) = A_0 + A_1\beta + A_2\beta^2 + A_3\beta^3 + A_4\beta^4 \quad (2.13)$$

$$A_0 = +0.0075 \frac{S}{d} + 1.90$$

$$A_1 = +0.0800 \frac{S}{d} - 3.39$$

$$A_2 = -0.2175 \frac{S}{d} + 15.40 \quad (2.14)$$

$$A_3 = +0.2825 \frac{S}{d} - 26.24$$

$$A_4 = +0.1450 \frac{S}{d} + 26.38$$

A_i ($i=0,1, \dots, 4$) katsayıları lineer interpolasyon ile $S/d=4$ ve 8 için Brown ve Srawley tarafından verilen katsayılardan elde edilmiştir [47].

$$\delta_P = \frac{P_{max}}{4bE} \left(\frac{S}{d} \right)^3 \left[1 + \frac{5wS}{8P_{max}} + \left(\frac{d}{S} \right)^2 \left\{ 2.70 + 1.35 \frac{wS}{P_{max}} \right\} - 0.84 \left(\frac{d}{S} \right)^3 \right] + \frac{9}{2} \frac{P_{max}}{bE} \left(1 + \frac{wS}{2P_{max}} \right) \left(\frac{S}{d} \right)^2 F_2(\alpha_e), \quad (2.15)$$

Kirişin rijitliğindeki azalma hem stabil çatlak büyümesinin hem de kırılma süreci bölgesinin oluşumunun bir sonucudur [58].

2.3.2. Çift-K Modeli

Çift-K Modeli, beton yapılarda kırılmayı modellemek için, başlangıç gerilme şiddet çarpanı K_{ic}^{ini} ve kritik gerilme şiddete çarpanı K_{ic}^{un} gibi iki parametre kullanmaktadır [10, 11]. Yöntemin diğer kırılma modellerinden en önemli farkı, onların sadece çatlağın ani gelişmesini dikkate alan parametreler ile beton yapılar modellemesidir. Çift-K yönteminde ise buna ilave olarak çatlağın yayılmaya başlama kriterini de dikkate almaktadır. Ancak Çift-K yönteminde K_{ic}^{ini} 'i belirlemek için kohezif gerilme şiddet çarpanı K_{ic}^c ifadesinin hesaplanması gerekmektedir. K_{ic}^c ise bazı ampirik ifadelerle dayanmakta ve hesabında numerik integral tekniklerine başvurulmaktadır. Bununla birlikte son zamanlarda, K_{ic}^c 'nin hesabı için direkt integrallenebilir, yarı-analitik bir yöntem, İnce [12] tarafından geliştirilmiş ve literatürden elde edilen 94 deney verisi kullanılarak yöntem test edilmiş ve analitik yaklaşımın sonuçlarının oldukça uygun ve ümit verici olduğu tespit edilmiştir.

Lineer olmayan kırılma mekaniği yaklaşımları içerisinde, Çift-K Modeli [10], beton bir yapıda, gerilme şiddet çarpanı K_I (burada sadece mod I durumu dikkate alınmaktadır) başlangıç gerilme şiddet çarpanı K_{ic}^{ini} değerine eriştiğinde çatlağın yayılmaya başladığını ve kritik gerilme şiddet çarpanı K_{ic}^{un} değerine eriştiğinde ise çatlağın ani yayıldığını kabul etmektedir. Çatlağın yayılmasını önlemek amacıyla kırılma sürecinde yarı kırılğan malzemelerde bir Çift-K kriteri önerilmiştir. Çift-K kriteri iki boyutlu-bağımsız parametreden meydana gelir. Her iki terim gerilme şiddet faktörüdür. Biri K_{ic}^{ini} ile ifade edilen ilk kırılma tokluğunu yansıtır, P_{ini} doğrudan ilk çatlama yükü olarak değerlendirilebilir ve öngörülen çatlak uzunluğu a_0 , LEKM'in formülünde kullanılır. Diğeri ise, yine aynı formül olan LEKM'i kullanarak, maksimum yük P_{max} , ve etkili çatlak uzunluğu a_c 'yi ekleyerek kararsız kırılma tokluğu ile ifade edilen K_{ic}^{un} 'a değinir. İki parametrenin değerleri olan K_{ic}^{ini} ve K_{ic}^{un} , küçük boyutlu üç noktalı eğilme çentikli

kirişlerden elde edilir ve büyük boyutlu basınç dayanımı numuneleri gösteriyor ki K_{Ic}^{ini} ve K_{Ic}^{un} u bağımsız-boyutludur. Çift-K kırılma kriteri matematiksel olarak aşağıdaki gibi tarif edilir;

- $K_I = K_{Ic}^{ini}$ olduğu zaman, önceden oluşmuş olan çatlakla ilk çatlama başlar;
- $K_{Ic}^{ini} < K_I < K_{Ic}^{un}$ olduğu zaman, çatlak giderek gelişir;
- $K_I \geq K_{Ic}^{un}$ olduğu zaman ise; çatlak istikrarsız yayılır [10];

K_{Ic}^{un} kırılma parametresi iki parametrelili modele [9] benzer olarak RILEM [59] tarafından önerilen, komplians yönteminden hesaplanmaktadır. Komplians yönteminde kırılma parametreleri, Şekil 2.11'de görüldüğü gibi çentikli bir üç noktalı eğilme numunesinin Yük-Çatlak Ağzı Açılımı (P-CMOD) ilişkisinden belirlenir [59]. Modeldeki kritik çatlak boyu a_c , başlangıç (C_i) ve pik yükte ölçülen sekant (C_s) gibi iki komplians değerinden faydalanarak hesaplanır (Şekil 2.11b). Sonuç olarak, başlangıç ve pik yükteki sekant komplians değerlerinden, betonun elastisite modülü eşitliğiyle a_c deneme-yanılma yöntemiyle bulunabilir:

$$E = \frac{6Sa_0V(a_0)}{C_i b d^2} = \frac{6Sa_cV(a_c)}{C_s b d^2} \rightarrow a_c V(a_c) = \frac{a_0 V(a_0) C_s}{C_i}, \alpha = \frac{a}{d} \quad (2.16)$$

K_{Ic}^{un} parametresi, LEKM'e ait denklemle aşağıdaki şekilde hesaplanabilir:

$$K_{Ic}^{un} = \frac{3P_c S}{2bd^2} \sqrt{\pi a_c} Y(\alpha_c) \quad (2.17)$$

İfade (2.16)'daki $V(\sigma)$ ve İfade (2.17)'deki $Y(\sigma)$ fonksiyonları $S/d=4$ olan kirişler için aşağıdaki gibi verilebilir [68]:

$$V(\alpha) = 0.76 - 2.28\alpha + 3.87\alpha^2 - 2.04\alpha^3 + \frac{0.66}{(1-\alpha)^2} \quad (2.18)$$


$$Y(\alpha) = \frac{1.99 - \alpha(1-\alpha)(2.15 - 3.93\alpha + 2.7\alpha^2)}{\sqrt{\pi}(1+2\alpha)(1-\alpha)^{3/2}} \quad (2.19)$$

Başlangıç gerilme şiddet çarpanını K_{Ic}^{ini} hesaplamak için ilk önce Şekil 2.11.c'de

detaylandırıldığı gibi, çatlak gerisinde yer alan kohezif gerilmelerin sebep olduğu kohezif gerilme şiddet çarpanını K_{Ic}^c in hesaplanması gerekir. Çift-K yönteminde K_{Ic}^c in değeri, Jenq ve Shah [71] tarafından tanımlanan ifade (2.20) ile hesaplanmaktadır ve bu ifade aslında, Tada v.d. [68] in önerdiği yaklaşımın basitleştirilmiş halidir.

$$K_{Ic}^c = \int_{a_0}^{a_c} \frac{2\sigma(\frac{x}{a_c})}{\sqrt{\pi a_c}} F\left(\beta = \frac{x}{a_c}, \alpha = \frac{a_c}{d}\right) dx \quad (2.20)$$

$$F(\beta, \alpha) = \frac{3.52(1-\beta)}{(1-\alpha^2)^{1.5}} - \frac{4.35-5.28\beta}{(1-\alpha)^{0.5}} + \left[\frac{1.3-0.3\beta^{1.5}}{(1-\beta^2)^{0.5}} + 0.83 - 1.76\beta \right] [1 - \alpha(1 - \beta)] \quad (2.21)$$



Şekil 2.11. Çift-K modelde kırılma parametrelerinin tayini [12].

- a)** Çentikli üç noktalı eğilme numunesi **b)** tipik bir P-CMOD diyagramı.
c) K_{Ic}^c nin hesap şekli **d)** iki-lineer doğrudan oluşan gerilme-çatlak açılımı kanunu

Ancak ifade (2.20) un singülariteden dolayı analitik çözümü yoktur ve Gauss-Chebyshev yöntemiyle sonuç bulmak mümkündür [10]. Çatlak gerisinde oluşan gerilme dağılımının fonksiyonu $\sigma(x)$ için Şekil 2.11d'de görülen iki lineer doğrudan oluşan gerilme çatlak açılımı ($\sigma - w$) bağıntısı kullanılır ve bu eğrinin altında kalan alan betonun

kırılma enerjisine G_F eşittir. $\sigma - w$ ilişkisinin kritik noktaları, f'_c betonun basınç mukavemeti, f'_t betonun çekme mukavemeti ve d_{max} maksimum agrega çapı olmak üzere aşağıdaki denklemlerden belirlenebilir [10]:

$$\alpha_F = 9 - d_{max}/8 \quad (2.22)$$

$$G_F = (0.00025d_{max} + 0.002)f_c^{0.7} \quad (2.23)$$

$$w_0 = \alpha_F G_F / f_t \quad (2.24)$$

$$\sigma_s = \frac{f_t}{\alpha_F} \left(2 - \frac{f_t CTOD_c}{G_F} \right) \quad (2.25)$$

Yukarıdaki ifadelerde f'_c ve f'_t [MPa], d_{max} [mm] ve G_F [N/mm] birimindedir. İfade (2.23) CEB-FIB şartnamesi [59] göre hesaplanmaktadır. Modelde Şekil 2.11d'deki $w_s = CTOD_c$ yani kritik çatlak ucu açılımına eşit alınmaktadır. Bu değer iki parametrelili modele benzer olarak aşağıdaki gibi hesaplanabilir [14]:

$$CTOD_c = \frac{6P_c S \alpha_c}{E b d^2} V \left(\frac{\alpha_c}{d} \right) \sqrt{\left(1 - \frac{\alpha_0}{\alpha_c} \right)^2 + \left(1.081 - 1.149 \frac{\alpha_c}{d} \right) \left(\frac{\alpha_0}{\alpha_c} - \frac{\alpha_0^2}{\alpha_c^2} \right)} \quad (2.26)$$

Sonuç olarak başlangıç gerilme şiddet çarpanı süper pozisyon kaidesi gereğince ifade (2.27)'dan hesaplanabilir [11]:


$$K_{Ic}^{ini} = K_{Ic}^{un} - K_{Ic}^c \quad (2.27)$$

2.4. Yapay Sinir Ağları

2.4.1. Yapay Sinir Ağlarının Tanımı

Yapay sinir ağları (YSA) temelde insan beyninin öğrenme davranışlarını taklit etmeye çalışırlar. YSA insan beyni ile karşılaştırıldığında oldukça basit ve küçük boyutta olmalarına rağmen, bilgi ve bilgi işleme sürecinde insan beyni ile olan benzerlikleri nedeniyle bazı güçlü özelliklere sahiptirler. Bu nedenle YSA mühendislik uygulamalarında etkili bir araçtır [77].

Basit tanımıyla yapay sinir ağları, birçok basit işlemci elemandan oluşan yapılardır. Bu elemanlar farklı formda ifade edilebilen nümerik verileri taşıyan “bağlantılar” veya “ağırlıklar” ile birbirine bağlıdırlar [77]. Bu elemanları biyolojik sinir sisteminden esinlenerek ortaya çıkmıştır. Doğada olduğu gibi yapay sinir ağları unsurlar arasındaki bağlantıları sağlar. Bir işlevi gerçekleştirmek için yapay sinir ağı ile ilgili değerler ayarlanarak, elemanlar arasındaki bağlantılar (ağırlıklar) ile yapay sinir ağları eğitilebilirler. Eğitilmiş ve ayarlanmış yapay sinir ağları genellikle belirli bir girdi sonucu belirli bir hedef çıktı oluştururlar. Aşağıda Şekil 2.12.’de böyle bir yapay sinir ağının durum gösterilmiştir.



Şekil 2.12. Basit bir yapay sinir ağı yapısı

Yapay sinir ağılarındaki gelişmelerin temel kaynağı, beynimizin rutin olarak gerçekleştirdiği karmaşık hesaplamaları yapay, belki zeki davranış sergileyen sistemlerin yapılabileceği ümididir [77].

Yapay Sinir Ağlarının konvansiyonel yöntemlere oranla bir problemi, problemin kendi özelliğine ait bir takım matematiksel formülasyonlar kullanarak çözmek yerine problemi örnekler üzerinden öğrenmeleri, değişen şartlara uyumlu olabilmeleri ve gürültülü datalardan bir problemin özünü öğrenebilmeleri gibi avantajları nedeniyle özellikle mühendislikte çok geniş bir potansiyonel uygulama alanına sahiptir [9].

Sinir ağıları insan beynindeki nöronlara benzer olarak çalışan karmaşık sistemlerdir. Yani, bu ağılar insan beyninin biyolojik fonksiyonlarının basit bir modellenmesinden ibarettir. Ağ, kendisine sunulan veriler arasında bağlantılar kurarak problemi öğrenmekte, deneysel sonuçları depolamakta ve bunları kullanıma hazırlamaktadır [74].

Yapay sinir ağıları çeşitli karmaşık işlevleri gerçekleştirmek için eğitilmişlerdir. Tanımlanma, sınıflandırılma, konuşma, görme ve kontrol sistemleri gibi. Günümüzde bilgisayar ve insanlar için zor olan problemlerin çözümü için yapay sinir ağıları eğitilerek bu problemlere çözüm bulunabilir. Bu yapay sinir ağılarından oluşan paradigmlar mühendislik, finans ve diğer birçok uygulama alanında kullanılabilir.

Sinir ağıları elli yıllık bir geçmişe sahiptir. Yapay sinir ağıları son on beş yıl içinde uygulama alanı bulmuştur ve bu süreç hızla gelişmektedir. Böylece, belirgin bir biçimde kontrol sistemleri, optimizasyon terminoloji, temel matematik ve tasarım gibi farklı alanlarında yıllarca uygulanmıştır. Gelecekte daha fazla alanda yer alacağı ve kullanılacağı tahmin edilmektedir.

Bilgisayar tekniğindeki gelişmeler farklı analiz tekniklerinin ortaya çıkmasını sağlamıştır. Bu tekniklerden biri olan yapay zekâ insan beyninin çalışma biçimini model edinen bir uygulamadır. 1990'lı yıllardan beri bilgisayarların öğrenmesini sağlayan Yapay Sinir Ağları teknolojisinde oldukça hızlı bir gelişme görüldü. Bu teknoloji, kısa zamanda araştırmacıların dikkatlerini üzerine çeken bir bilim dalı olmayı başardı ve elde edilen başarılar hem yapay sinir ağılarının önemini hem de bu sistemlere olan ilgiyi artırmaktadır. Bilgisayar, endüstri, tıp, ekonomi ve askeri uygulamalarda başarıyla kullanılan bu teknik, yapı mühendisliğinde de kullanılmaya başlanmıştır [75].

YSA teknolojisi hesaplamaya tamamen farklı bir anlayış getirmiştir. Ağ hesaplaması algoritmik olmayan bir hesaplama yöntemidir ve büyük ölçüde paralel hesaplama yöntemlerinden yararlanmaktadır. YSA programlanmış bir yazılımdan ziyade bir


uygulamayı öğrenir ve örnekler aracılığıyla eğitilir. YSA bilgiyi bilgisayar hafızası gibi belirli yerlerde depolamak yerine, bilgi formlarını bağlantı ağırlıkları şeklinde ağ boyunca dağıtırlar. Rumelhardt algılayıcı isminde gizli birimlerle birlikte biyolojik bir sinir ağının formülleşmiş modeli için bir öğrenme algoritması türetmiştir. Literatürde ismi geri yayılım algoritması diye geçen öğrenme algoritması en geniş kullanım alanına sahip algoritmadır. Bu sistem mühendisli problemlerinin çözümünden en çok kullanılan öğrenme algoritmasıdır [77].

2.4.2. Yapay Sinir Ağlarının Özellikleri

Yapay sinir ağları fikri başlangıçta insan beyninin biyofizyolojisini modellemek, onun nasıl çalıştığını ve fonksiyonları anlamak için ortaya çıkmıştır. Çalışmanın amacı İnsanın düşünme sürecini yeteneğine sahip bir model ortaya koymaktır. Yapay sinir ağları bu akıllı düşünme yeteneğini elde edebilmek için yoğun enterkonnekte sisteme sahip paralel olarak çalışabilen basit hesaplama elemanlarından faydalanmıştır. Yapay sinir ağları sisteminin geliştirilmesinin altında yatan temel düşünce adaptif öğrenme algoritmaları aracılığıyla bilgiyi zaman içinde edinen ve depolayan yeni bir tür bilgisayar mimarisi sağlamaktır[9].

Yapay sinir ağları ile yapılan modeller, insan beyninin bir probleme bulduğu çözümün benzeri ama çok daha kısıtlanmış halidir. Biyolojik sinir ağlarından esinlenerek tasarlandığı için biyolojik sinir ağlarının özelliklerine sahiptirler. Biyolojik sinir hücrelerinden esinlenerek 1940'lı yıllarda ortaya çıkarılan yapay sinir hücre modeli; “ve”, “veya” ve “değil” gibi mantık işlemlerinin sayısal olarak modellerinin oluşturulabileceğini göstermiştir. Böylece basit biyolojik sinir sisteminin incelenmesi ve onlara benzer şekilde çalışan YSA modellerinin geliştirilmesi mühendislik, matematik, ekonomi, askeri alan, tıp ve psikoloji gibi dallardaki araştırmacıların ortak çalışma konusu haline gelerek kullanım alanı genişlemiştir [76].

Aşağıdaki şekilde tipik bir sinir ağının bağlantı Şekil 2.13' de verilmiştir.



Şekil 2.13 Bir yapay sinir ağının tipik olarak bağlantı şekli

2.4.2.1. Bellek ve Genelleme

Genelleme özelliği ağ yapısının eğitim esnasında ilgilendiği problemi öğrenmesi, kullanılan nümerik bilgilerden eşleştirme esnasında kullanılan bilgileri çıkarması ve böylelikle eğitim sırasında kullanılmayan girdiler için de anlamlı yanıtlar üretebilmesidir. Yapay sinir ağ belleğinin yapısı; eksik, gürültülü ve tam seçilemeyen bir giriş uygulandığı zaman da anlamlı çıkışlar elde etmeye uygundur ki buna genelleme denir.

Yapay sinir ağları bilgileri ağ içerisinde yerel bellekler oluşturarak diğer nöronlara aktarır. Bir yapay nöral ağda her bir nöronun bir yerel belleği ve sinir ağının o andaki bilgi durumunu belirten nöronlar arası bağlantı ağırlıkları bulunmaktadır. Ağda çıkışı oluşturan giriş bilgisi, ağın içinde birçok yerel bellek şeklinde dağıtılmış olup nöron ağın bilgiyi bu şekilde saklaması en önemli özelliklerindendir.

2.4.2.2. Eksik Bilgilerle Çalışabilme

Yapay sinir ağları, geleneksel sistemlerin aksine kendileri eğitildikten sonra eksik bilgiler ile çalışabilmekte ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç

üretebilmektedir. Ana sistem bozulmadığı sürece, sistem zarar görse bile eğer performansı düşürmeyecek bir bölüm zarar görmemişse sistem çalışır ve başarısız olmaz.

Geleneksel işlemcilerde, tek bir merkezi işlemci eleman her hareketi sırasıyla gerçekleştirirler. Yapay sinir ağları, her biri büyük bir problemin bir parçası ile ilgilenen çok sayıda basit işlemci elemanlardan oluşmaları ve bağlantı ağırlıklarının ayarlanabilmesi gibi özelliklerinden dolayı önemli derecede esnek bir yapıya sahiptirler.

2.4.2.3. Doğrusal Olmama ve Paralellik

Yapay nöronların doğrusal olmama özelliği yapay sinir ağlarının doğadaki hemen hemen her probleme uygulanabilmesini sağlamaktadır. Ağ yapısı içerisinde kullanılan doğrusal olmayan transfer fonksiyonları tarafından bu özellik YSA'na kazandırılır [77].

Nöronlar lineer olmadığı için, bunlardan meydana gelen YSA'da lineer değildir. Bu özellikleri nedeniyle daha karmaşık problemleri lineer tekniklerden daha doğru çözerler. Günümüzde kullanılan bilgi işleme yöntemleri genelde seri işlemlerden oluşmaktadır. Yapay nöral ağlar aynı zamanda son derece paralellığe sahiptirler. Bağımsız işlemleri aynı anda çok hızlı yürütülebilir.

2.4.2.4. Öğrenme

Bu özellik YSA' nı diğer veri işleme yöntemlerinden ayıran en önemli özelliklerinden biridir. YSA uygun olarak tasarlanarak elde edilmek istenen sonuçlara ulaşılabilir. Öğrenme verilen örnekler ile elde edilir. Öğrendiklerini genelleme yapar ve diğer problemlere de çözüm bulur.

YSA'nın bir problemi öğrenmesi için problemin giriş verilerine karşılık gelen çıkış verilerinin veya sadece giriş verilerinin sağlanması gerekmektedir. Giriş ve çıkış verileri ile tanımlı öğrenme kümesi yeterli sayıda örnek içermelidir. Öğrenme sadece öğrenme verilerini içeren kümenin yeterliliği ile ilgili değildir. YSA yapısının da uygun düzenlenmiş olması gerekmektedir. Öğrenme süreci sistem girişleri ve sistem çıkışı arasındaki ilişkiyi veya sadece giriş verileri arasındaki ilişkilendirmeyi tanımlayan ağırlık verilerinin elde edilme süreci olarak ta tanımlanabilir [78].

2.4.2.5. Adaptasyon

YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilmekte, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilmektedir. Bu özelliği ile yapay sinir ağları, uyarlamalı örnek tanıma, sinyal işleme, sistem tanımlama ve denetim gibi alanlarda etkili olarak kullanabilmektedir.

2.4.2.6. Sınırsız Sayıda Değişken ve Parametre Kullanma

Yapay sinir ağları sınırsız sayıda değişken ve parametre ile çalışabilmektedir. Bu sayede mükemmele yakın öngörü doğruluğu ile genel çözümler sağlanabilmektedir.

2.4.2.7. Hataya ve Gürültüye Karşı Duyarlılık ve Tolerans:

YSA'nın genelleme yeteneği gerçekleştirilen testlerle denenir. Genelleme, yeterli seviyede ise giriş vektörünü tanımlayan parametrelerden bazılarının verilmemesi veya sağlanamaması durumunda ya da ağırlıklarından bazılarının bozulması ve kullanılamaz duruma gelmesi durumunda da giriş vektörünü karşılayan çıkış verilerinin YSA tarafından kabul edilebilir doğrulukta üretilmesidir. YSA giriş vektöründen veya kendi yapısından kaynaklanan hataları yok edebilir. Gürültü balansı bu özellik YSA'nın klasik hesaplama yöntemlerine göre bir üstünlüğüdür. YSA'da çok sayıda bulunan işlemci eleman paralel dağıtılmış bir yapıya sahiptir ve ağırlık sahibi olduğu bilgi, ağırdaki tüm bağlantılara dağıtılmıştır. Giriş veri kümesinde bulunabilecek herhangi bir gürültü, bütün ağırlıklar üzerine dağıtıldığından dolayı, gürültü etkisi ihmal edilebilir. Geleneksel yöntemlere göre hatayı ihmal etme yetenekleri daha fazladır [78].


2.4.3. Yapay Sinir Ağlarının Yapısı ve Temel Bileşenleri

2.4.3.1. Biyolojik Sinir Hücresi Yapısı

Sinir hücreleri birbirleri ile bağlanarak işlevlerini yerine getirirler. İnsan beyni öğrenme, birleştirme, uyarılma ve genelleştirme yeteneği nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağılmış bir bilgi işletme sistemi olarak tanımlanabilir.

Beynin gücü çok sayıdaki sinir hücresi ve aralarındaki sonsuz sayıdaki bağlantılardan, genetik yapıları ile öğrenme yeteneklerinden kaynaklanmaktadır. Beynin

yapısını basitçe nöronlar bulundukları yer ve işlevlerine göre alıcı nöronlar (afferent ya da receptor), tepki nöronları (efferent ya da effector), ara nöronlar (interneurons) olmak üzere üç grupta sınıflandırılırlar. Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beynin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem olarak açıklanmaktadır. Bu işlem sırasında bilgi alınır, yorumlanır ve karar verilir. Alıcı nöronlar çevreden hücrelere gelen işaretleri (ses, ışık gibi) algırlar. Tepki nöronları beyinden vücudun bezlerine ve kaslarına giden çıkışları taşırlar. Bu iki tür nöron arasındaki ara nöron olarak bilinen diğer tüm nöronlar algılama, düşünme ve hafıza ile ilgili işlemleri üstlenirler [79]. Şekil 2.14’de biyolojik sinir sistemi blok gösterimi gösterilmiştir.




Şekil 2.14 Biyolojik sinir sistemi blok gösterimi

Sinir hücreleri nöron olarak bilinir. Nöron, özellikle beyin olmak üzere sinir sisteminin temel birimidir ve başlıca üç kısımdan oluşur. Bunlar:

- Gövde (cell body),
- Gövdeye giren sinyal alıcı lifler (dendrit),
- Gövdeden çıkan sinyal iletici lifler (axon).

Şekil 2.15’de bir biyolojik nöron yapısı görülmektedir. Dendritler çevre hücrelerden gelen sinyalleri (impulse) alıp, gövdeye ulaştırırlar. Her nöron, dendritler

vasıtasıyla diğer nöronlardan gelen işaretleri alan ve birleştiren basit bir mikro işleme birimidir [80].



Biyolojik sinir hücresi

Şekil 2.15 Biyolojik nöron yapısı

Bir nöronun aksonu sinaps vasıtasıyla diğer nöronların dentritlerine bağlanır. Bu sinaps uçlarındaki iletim doğal olarak kimyasaldır ve işaretin miktarı, akson tarafından serbest bırakılan kimyasalların büyüklüğüne bağlı olarak transfer edilir ve dendritler vasıtasıyla alınır. Bu sinaptik büyüklüğe göre beyin öğrenimini belirler. Bu sinaps, beyin temel hafıza mekanizmasına dayanarak nöron içerisindeki bilginin işlenmesi ile birleştirilir.

Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantıların ayarlanması ile oluşturulur. İnsan yaşamı süresince tecrübeler edinir, bu tecrübelerin sinaptik bağlantıları etkilediği ve öğrenmenin bu şekilde geliştiği düşünülmektedir.

Yapay sinir ağları beyinin çalışma sistemi örnek alınarak geliştirilmiştir. Aralarında benzerlikler bulunmaktadır [82]. Aşağıdaki Tablo 2.1.' de bu benzerlikler gösterilmiştir [77].

Tablo 2.1. Biyolojik sinir sistemi ile yapay sinir ağlarının benzerlikleri [84].


Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir Hücresi (Nöron)	İşlemci Eleman (Yapay Sinir Hücresi, Düğüm)
Sinaps	İşlemci Elemanlar Arasındaki Bağlantı Ağırlıkları
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	İşlemci Eleman Çıktısı

Yapay sinir ağlarında bu ayarlamayı yapmak ve öğrenmeyi sağlamak için ağırlık fonksiyonları kullanılmaktadır, insanın deneme yanılma yoluyla öğrenmesi yapay sinir ağlarında yinelemeli eğitim sayesinde gerçekleştirilmektedir [84].

Yapay sinir ağları kavramı beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya atılmış ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin, ya da literatürdeki ismiyle nöronların matematiksel olarak modellenmesi üzerinde yoğunlaşmıştır [85].

2.4.3.2. Yapay Sinir Hücresi Yapısı

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri mühendislik biliminde işlem elemanları olarak da adlandırılmaktadır. Şekil 2.16.'da yapay bir sinir (düğüm) gösterilmiştir [86].



Şekil 2.16. Yapay sinir hücresinin yapısı

Girişler P_i sembolüyle gösterilmiştir. Bu girişlerin her biri ağırlık w_{ij} ile çarpılır. Basitçe, bu ürünler eşik değeri θ_j ile toplanır ve sonucu oluşturmak için etkinlik işlevi ile işlem yapılır ve y_i çıkışı alınır.

2.4.3.2.1. Girdiler

Bir yapay sinir hücresine (proses elemanına) dış dünyadan gelen bilgilerdir. Bunlar ağız öğrenmesi istenen örnekler tarafından belirlenir. Yapay sinir hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendi kendisinden de bilgiler gelebilir.

2.4.3.2.2. Ağırlıklar

Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Şekil 2.16'daki Ağırlık 1, Girdi 1'in hücre üzerindeki etkisini göstermektedir. Ağırlıkların büyük ya da küçük olması önemli veya önemsiz olduğu anlamına gelmez. Bir ağırlığın değerinin sıfır olması o ağ için en önemli olay olabilir. Eksi değerler önemsiz demek değildir. O nedenle artı veya eksi olması etkisinin pozitif veya negatif olduğunu gösterir. Ağırlıklar değişken veya sabit değerler olabilirler.

2.4.3.2.3. Toplama Fonksiyonu

Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi bulunmuş olur. Bu (2.28) ifadesi şeklinde formüle edilmektedir.

$$NET = \sum_n^i G_i A_i \quad (2.28)$$

burada G girdileri, A ağırlıkları, n ise bir hücreye gelen toplam girdi (proses elemanı) sayısını göstermektedir. Yalnız yapay sinir ağlarında daima bu formülün kullanılması şart değildir. Uygulanan yapay sinir ağı modellerinden bazıları kullanılacak toplama fonksiyonunu belirleyebilmektedir. Literatürde yapılan araştırmalarda toplama fonksiyonu olarak değişik formüllerin kullanıldığı görülmektedir. Bir problem için en uygun toplama fonksiyonunu belirlemek için bulunmuş bir formül yoktur. Genellikle deneme yanılma yolu ile toplama fonksiyonu belirlenmektedir. Bir yapay sinir ağında bulunan proses elemanlarının tamamının aynı toplama fonksiyonuna sahip olmaları gerekmez. Her proses elemanı bağımsız olarak farklı bir toplama fonksiyonuna sahip olabilecekleri gibi hepsi aynı proses elemanına sahip olabilir. Hatta ağın bazı proses elemanları grup halinde aynı toplama fonksiyonuna sahip olabilir. Diğerleri ise farklı fonksiyonlar kullanabilirler. Bu tamamen tasarımcının kendi öngörüsüne dayanarak verdiği karara bağlıdır.

2.4.3.2.4. Transfer Fonksiyonu

Yapay nöronun davranışını belirleyen önemli bir etken transfer fonksiyonudur. Buna aynı zamanda “öğrenme eğrileri” de denir. Transfer fonksiyonu hücreye gelen net girdiyi, diğer bir deyişle toplama fonksiyonunu işleyerek bu hücreye gelen girişlere karşılık olan çıkışı belirler [86].

Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi transfer fonksiyonunda da çıktıyı hesaplamak için değişik formüller kullanılmaktadır. Bazı modeller (mesela çok katmanlı algılayıcı) bu fonksiyonun türevinin alınabilir bir fonksiyon olmasını şart

koşmaktadır. Toplama fonksiyonunda olduğu gibi transfer fonksiyonunda da ağıın proses elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Bazı elemanlar aynı fonksiyonu diğerleri farklı fonksiyonları kullanabilirler.

Transfer fonksiyonu da yapay sinir ağlarının farklı modelleri için farklı olabilir. En uygun transfer fonksiyonunu belirlemek için geliştirilmiş bir fonksiyon yoktur. Toplama fonksiyonuna benzer şekilde hücrelerin hepsi için aynı transfer fonksiyonu kullanma zorunluluğu yoktur. Bazıları aynı aktivasyon fonksiyonunu kullanırken bazıları kullanmayabilir [77].


Günümüzde en yaygın olarak kullanılan çok katmanlı algılayıcı modelinde genel olarak transfer fonksiyonu olarak sigmoid fonksiyonu kullanılmaktadır. Bu fonksiyon (2.29) ifadesi ile gösterilmektedir.

$$F(NE\text{T})= \frac{1}{1-e^{-NE\text{T}}} \quad (2.29)$$

Birçok transfer fonksiyonu yer almaktadır. Aşağıda en çok kullanılan dört transfer fonksiyonu verilmiştir.

2.4.3.2.4.1. Hard-Limit Transfer Fonksiyonu

Girdi değerinin belirlenen bir eşik değerinin altında ya da üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerlerini alır. Şekil 2.17. 'de fonksiyon görülmektedir.




Şekil 2.17. Hard-limit transfer fonksiyonu

Burada, n fonksiyonun girişi, a ise çıkışıdır: $a=f(n)$. Bu fonksiyonda, giriş değeri 0 (sıfır)'dan büyükse çıkış değeri 1 (bir), giriş değeri 0 (sıfır)'dan küçükse çıkış değeri 0

(sıfır) olmaktadır. Nöronların sınıflandırılmasında algılayıcıları oluşturmak için bu fonksiyonu kullanacağız.

2.4.3.2.4.2. Lineer Transfer Fonksiyonu


Lineer Filtre problemlerinde doğrusal yaklaşım olarak kullanılır. Gelen net girdileri doğrudan hücre çıkışı olarak vermektedir. Şekil 2.18.' de lineer transfer fonksiyonu görülmektedir.



Şekil 2.18. Lineer transfer fonksiyonu

2.4.3.2.4.3. Log-Sigmoid Transfer Fonksiyonu

Sigmoid fonksiyonunun grafiği aşağıda verilmiştir. Artı ve eksi sonsuz arasındaki herhangi bir giriş değeri için, çıkış 0 ile 1 arasında olmaktadır. Şekil 2.19.' da görülmektedir.




Şekil 2.19. Log-Sigmoid transfer fonksiyonu

Bu transfer fonksiyonu geri yayılım ağlarında kullanılır. Türevi alınabilir. Doğrusal olmayan problemlerin çözümünde tercih edilir.

2.4.3.2.4.4. Hiperbolik Tanjant Transfer Fonksiyonu

Bu fonksiyonun türevi alınabilir. Aslında sigmoid aktivasyon fonksiyonunun farklı bir çeşitidir. Doğrusal olamayan problemlerin çözümünde tercih edilir. Artı ve eksi sonsuz arasındaki herhangi bir giriş değeri için, çıkış -1 ile 1 aralığında olur. Şekil 2.20’ de fonksiyon görülmektedir.



Şekil 2.20. Hiperbolik tanjant transfer fonksiyonu

2.4.3.2.5. Çıkış İşlevi

Çıkış aktivasyon fonksiyonunun sonucunun dış dünyaya veya diğer sinirlere gönderilmesidir. Bu sinirin çıkışı kendine ve kendinden sonra gelen bir ya da daha fazla sayıda sinire giriş olabilir.

Biyolojik sinirde olduğu gibi bir sinirin birden fazla girişi varken tek bir çıkış etkinliği vardır. Ancak ağ seklinde gösterildiğinde bir sinirin birden fazla çıkışı varmış gibi gözükür. Bu sadece sekil üzerinde böyledir.

Her bir düğümün çıkışı aktivasyon fonksiyonunun sonucuna eşittir. Fakat bazı ağ yapılarında komsu düğümler arasında yarışma oluşturmak için aktivasyon fonksiyonlarını yeniden düzenlenebilir. Bunun sonucunda yarışmacı düğümlerin girişleri, hangi düğümlerin öğrenme işlemine katılacağına karar verilmesine yardımcı olurlar [86].

2.4.4. Yapay Sinir Ağlarının Sınıflandırılması

2.4.4.1. Yapay Sinir Ağlarının Yapılarına Göre Sınıflandırılması


Yapay sinir ağları daha önce de bahsedildiği gibi birbirleri ile bağlantılı işlemcilerden (nöronlardan) oluşmuştur. Bu nöronlar arasındaki bağlantılar yapay sinir ağlarının yapılarını belirler. Bağlantıların nasıl olacağına öğrenme algoritmaları ile karar verilebilir. Yine öğrenme algoritmasına göre ağırlıkların değeri belirlenir. Genelde yapay sinir ağları yapılarına göre iki grupta incelenmektedir.

2.4.4.1.1. İleri Beslemeli Yapay Sinir Ağları

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

İleri beslemeli yapay sinir ağlarında, hücreler katmanlar şeklinde düzenlenmekte ve bir katmandaki hücrelerin çıktıları bir sonraki katmana ağırlıklar üzerinden girdi olarak verilmektedir.

Girdi katmanı, dışarıdan aldığı bilgileri hiçbir değişikliğe uğratmadan ara (gizli) katmandaki hücrelere iletmektedir. Bu bilgi, ara katman ve çıktı katmanında işlenerek ağ çıktısı belirlenir. Aşağıdaki Şekil 2.21’de ileri beslemeli ağ yapısı görülmektedir.




Şekil 2.21. İleri beslemeli ağ

İleri beslemeli yapay sinir ağları öğrenme algoritması olarak genellikle geri yayılım öğrenme algoritmasını kullanmakta ve bu nedenle bazen geri yayılım ağları olarak da adlandırılmaktadır. Şekil tanıma, sinyal işleme ve sınıflandırma gibi problemlerde genellikle bu topoloji uygulanır.

2.4.4.1.1. Çok Katmanlı Nöral Ağ Yapısı (MLP)

Çok katmanlı ağ yapısında giriş katmanı dış ortamdan gelen bilgileri kabul etmek ve iletmekle görevlidir. Transfer fonksiyonundan geçen bilgiler ara katman aktarılır. Ara katman, gizli katmanlardan oluşur. Ara katmanda, giriş katmanından gelen bilgileri işleyerek çıkış katmanına iletir. Çıkış katmanı ise ara katmandan gelen bilgileri dış ortama aktarmak ile görevlidir. Aşağıdaki şekilde çok katmanlı nöral ağ yapısı Şekil 2.22.' de gösterilmiştir.



Şekil 2.22. Çok katmanlı yapay sinir ağı yapısı

Birçok öğrenme algoritması bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir. Bir MLP modeli, bir giriş, bir veya daha fazla ara ve bir de çıkış katmanından oluşur. Her bir katmanda da bir veya daha fazla sayıda işlem elemanı bulunur. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Bunun için bu tip ağlar ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Giriş ve çıkış katmanındaki işlemci elemanı sayısı tamamen uygulanan

probleme bağlıdır. Ara katman sayısı ve ara katmanlardaki işlemci elemanı sayısı ise, deneme-yanılma yolu ile bulunur.

MLP ağlarında, ağa bir örnek gösterilir ve örnek neticesinde nasıl bir sonuç üreteceği de bildirilir (danışmalı öğrenme). Örnekler giriş katmanına uygulanır, ara katmanlarda işlenir ve çıkış katmanından da çıkışlar elde edilir. Kullanılan öğrenme algoritmasına göre, ağın çıkışı ile arzu edilen çıkış arasındaki hata tekrar geriye doğru yayılarak hata minimuma düşüncüye kadar ağın ağırlıkları değiştirilir.

İleri beslemeli ağlar, en genel anlamıyla giriş uzayıyla çıkış uzayı arasında statik haritalama yapar. Bir andaki çıkış, sadece o andaki girişin bir fonksiyonudur [77].

2.4.4.1.1.2. Öğrenme Vektör Nicelendirilmesi (Learning Vector Quantization) Ağı

Learning Vector Quantization (LVQ) ağı 1984 yılında Kohonen tarafından tasarlanmıştır. Bu nedenle Kohonen ağı olarak da bilinir. Giriş katmanındaki nöronlar ara katmandaki tüm nöronlarla bağlıdır. Ancak ara katmandaki farklı sayıdaki nöron grupları çıkış katmanındaki her bir nörona bağlıdır.

Bu ağın temel prensibi n boyutlu bir vektörü, bir vektörler setine haritalamaktır. Bu ağın öğrenme işlemi, girdi vektörünün hangi vektör seti tarafından temsil edileceğinin bulunmasını sağlamaktadır.

LVQ ağları özellikle sınıflandırma problemleri olmak üzere, sınıflandırma ve görüntü işleme problemlerinin çözümünde kullanılır. Bu ağ için kullanılan öğrenme takviyeli öğrenmedir [77].


2.4.4.1.2. Geri Beslemeli Yapay Sinir Ağları

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

Geri dönüşümlü ağlarda, ağın işlem elemanlarının çıkışları tekrar ağa belirli işlemler sonucunda giriş olarak gönderilir. Dinamik sistemlerde geri dönüşümlerden

kaynaklanan zaman gecikmesi önemli olduğu için bu konuda bir takım çalışmalar yapılarak değişik geri dönüşümlü ağ modelleri tasarlanmıştır [77].

Geri beslemeli yapay sinir ağlarında, en az bir işlemci elemanı çıktısı kendisine ya da diğer işlemci elemanlara girdi olarak verilmekte ve genellikle geri besleme bir geciktirme elemanı (ara katman veya çıktı katmanındaki aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşımakla görevli eleman) üzerinden yapılmamaktadır. Geri beslemeli, bir katmandaki işlemci elemanlar arasında olduğu gibi katmanlar arasındaki işlemci elemanlar arasında da olabilmektedir. Bu yapısı sayesinde geri beslemeli yapay sinir ağları, doğrusal olmayan dinamik bir davranış gösterirler. Bu sayede, geri beslemenin yapılış şekline göre farklı yapı ve davranışta geri beslemeli yapay sinir ağları elde edilebilir. Tek tabakalı bir perseptron Şekil 2.23’ de gösterilmiştir.




Şekil 2.23. Geri beslemeli yapay sinir ağı yapısı [81].

2.4.4.1.2.1. Elman Ağı

Elman ağı daha önce anlatılan çok katmanlı algılayıcı ağının öğrenme kuralına göre öğrenmektedir. Elman ağının Şekil 2.24’te görüldüğü gibi 4 çeşit işlemci elemanları vardır:

- Girdi elemanları,
- Ara katman elemanları,
- Çıktı elemanları,
- İçerik elemanları.



Şekil 2.24. Elman ağ yapısı

Bunlardan giriş ve çıkış elemanları dış dünya ile etkileşim halindedir. Giriş elemanları dış dünyadan bilgileri alır ara katmanlara iletirler. Çok katmanlı algılayıcılarda olduğu gibi, Elman ağında da giriş elemanlarının bilgi işleme özelliği yoktur.

Girişleri olduğu gibi ara katman elemanlarına gönderirler. Çıkış elemanları ise, ağın çıkışını dış dünyaya iletir. Çıkış birimlerinin bilgi işleme fonksiyonları doğrusaldır. Sadece kendilerine gelen bilgileri toplarlar. Ara katman elemanları ise, hem doğrusal hem doğrusal olmayan aktivasyon fonksiyonlarına sahip olabilirler. İçerik elemanları ara katman elemanlarının önceki aktivite değerlerini hatırlamak için kullanılmaktadır. Bu elemanlar bir adım gecikmeyi (one step time delay) içermektedirler. Bir önceki iterasyondaki aktivasyon değerlerini bir sonraki iterasyona giriş olarak taşırlar.

Geri dönüşümlerin ağırlıkları sabit olduklarından Elman ağına “Kısmi Geri Dönüşümlü Ağ” da denilebilir.

2.4.4.1.2.2. Hopfield Ağı

Hopfield ağı, John Hopfield tarafından 1982 yılında geliştirilmiştir. En çok optimizasyon problemleri için kullanılır. Hopfield ağı tek katmanlı ve geri dönüşümlü bir ağıdır. Bu ağ genellikle ikili (0 veya 1) ve bipolar (+1 veya -1) girişler kabul eder. Tek katmandaki işlemci elemanlarının her biri bir diğerine bağlanmıştır. Ayrıca her hücrenin çıkışı, bir ağırlıkla işleme tabi tutularak diğer hücrelere giriş değeri olarak dönmektedir. Ağın bağlantı değerleri bir enerji fonksiyonu olarak saklanır.

2.4.4.1.2.3. Uyarlanır Rezonans Ağı (ART)

ART ağları 1976 yılında Grossberg tarafından geliştirilmiştir. Birçok farklı ART ağı vardır. ART-1 ağının giriş ve çıkış olmak üzere iki katmanı vardır. İki katman birbirleriyle tamamen bağlantılıdır ve bağlantılar ileri ve geri yöndedir. İ'nci çıkış işlemci elemanının ileri yöndeki bağlantılarının ağırlıklarının oluşturduğu W vektörü, temsil ettiği sınıfın bir örneğini oluşturur. İleri bağlantılarının W_i vektörlerinin toplamı ART ağının uzun-dönem (long-term) hafızasını oluşturur. Bu vektörler, giriş desenine benzerlikleri ölçüsünde, çıkış işlemci elemanlarını belirlerler. Çıkış işlemci elemanlarının geri bağlantılarının V_i vektörleri ise, giriş deseninin, hafızadaki desenine yeterince benzeyip benzemediğini (o sınıfa ait olup olmadığını) kesin olarak belirlemek amacıyla kullanılır. Bu test vektörleri diyebileceğimiz V_i vektörleri ART ağının kısa-dönem (short-term) hafızasını oluştururlar. W_i , V_i 'nin normalize edilmiş halidir.

Bu ağlar belli giriş verisini analiz eder, olası özellikleri kontrol eder veya giriş vektörü içindeki bu özellikleri sınıflandırır. Birçok ağın temelini oluşturur. Öz örgütlemeli ağlara iyi bir örnektir. ART ağları eğitmek için danışmansız öğrenme yöntemi kullanılır [77].

2.4.4.1.2.4. Som Ağı

SOM tipi ağlar Kohonen tarafından geliştirilmiştir. Bu ağlar bir giriş ve bir çıkış katmanından oluşur. Ancak diğer ağlardan farklı olarak çıkış katmanı 2 boyutlu bir düzlemdir. Som tipi ağlarda yarışmayı kazanan işlemci elemanı 1 değerini alırken, diğer elemanlar 0 değerini alır. Sadece 1 değerini alan işlemci ve komşularının ağırlıkları değişir. Genellikle sınıflandırma amaçlı kullanılırlar. Bu ağlar öğrenmek için öğretmene ihtiyaç

duymazlar. Yani çıktıların bilinmesi zorunlu değildir. Çıkışları belli olmayan problemlerin çözümü için uygundur [86].

2.4.4.1.3. İleri Beslemeli Geri Yayılmalı Ağlar

İleri beslemeli geri yayılmalı ağlar 1970’li yıllarda geliştirilmiştir. Bu ağların geliştirilmesinde birçok araştırmacının katkıları bulunmaktadır. İleri beslemeli geri yayılmalı ağlara asıl katkıyı Rumelhart, Hinton ve Williams sağlamıştır (Rumelhart, et al., 1986). Ortaya çıktığı günden beri en çok kullanılan ağ türü olarak bilinmektedir. Bu ağlar çok sayıda farklı uygulama alanında kullanılmaktadır. İleri beslemeli geri yayılmalı ağların en büyük özeliği doğrusal olmayan yapı içeren problemlerde etkili olarak uygulanabilmesidir [73].

2.4.4.2. Öğrenme Algoritmalarına Göre Ağ Çeşitleri

Yapay sinir ağları insanlar gibi örneklerle eğitilirler. Yapay sinir ağlarının öğrenmesi bir çocuğun öğrenmesi gibidir. Sıcak bir nesneye dokunmaması gerektiğini deneyerek öğrenen çocuklar zamanla daha az sıcak olan bir cisme dokunabilme cesaretini gösterirler ve sıcak süt ile dolu bardağı elleriyle tutarlar. Yani çocuk sıcaklık bilgisini öğrenmiş olmaktadır. Yapay nöronlar da benzer olarak; mevcut örnek kümesi üzerinde girdi ve çıktı arasındaki bağıntıyı ağırlıkların değiştirilmesiyle öğrenirler [73].

Geleneksel bilgi işleme yöntemlerinde problemlerin çözümü geliştirilen algoritmalar ile sağlanır. Yapay sinir ağında ise öğrenme yeteneği problemlere çözüm bulma yoludur. Geleneksel yöntemlerde tam tanımı yapılmayan problemlerin çözümü olmamasına karşın, yapay sinir ağlarında öğrenme yeteneği sayesinde problemi çözme yeteneği öğrenilebilir.

İşlem elemanı ve ağ yapısı tasarlandıktan sonra yapay sinir ağlarının öğrenme işlemine başlanabilir. Yapay sinir ağı yönteminde problemlerin çözümü uygun değerli ağırlıklar ve bağlantılara bağlıdır.

Nöronların gelen işarete doğru cevap vermesi ve performansının artırılmasında en önemli olan eleman bağlantı ağırlıklarıdır. Bilgi ağırlıklarda tutulduğu için, ağırlıkların nasıl belirleneceği önemlidir.


Mümkün oldukça en uygun ağırlık değerleri bulunmalıdır, ama bunun belirli bir formülü bulunmamaktadır. Bu ancak ağların eğitilmesi ile sağlanabilir. Öğrenme problem hakkında gerekli bilgilerin verilmesi ile mümkündür. Öğrenme işlemi benzer bilgilerin bilgisayara verilmesi sonucu bilgisayarın tecrübe edinmesine benzetilebilir. Ağırlıkların değişmesi, ayarlanması belli kurallara göre yapılır. Buna öğrenme kuralları denir.

Yapay sinir ağının öğrenme işlemini gerçekleştirebilmesi için, sahip olduğu bütün ağırlıkların, ilgili problemde öğrenilmesi istenen özellikleri genelleştirecek şekilde doğru değerlere sahip olması gerekir. Bu doğruluk ne kadar artarsa ağın öğrenme işlemi o kadar iyi olur. Doğru ağırlık değerleri, bir öğrenme kuralına göre tespit edilirler. Çoğunlukla bağlantılara başlangıç değerleri olarak rasgele ağırlıklar atanır ve bu ağırlıklar eldeki örnekler incelendikçe bir kurala göre değiştirilerek doğru ağırlık değerleri bulunmaya çalışılır. Kısaca belirtmek gerekirse öğrenme kuralları, bir işlem elemanının örnekleri gördükçe kazandığı tecrübeye göre, ilgili bağlantı ağırlıklarını nasıl değiştireceğini belirleyen algoritmalarıdır. Öğrenme yöntemleri temelde üç grupta toplanır [112].

2.4.4.2.1. Danışmalı Öğrenme

Bu öğrenme metodunda yapay sinir ağına örnek olarak bir çıktı verilir. Bu çıktı ile ağın ürettiği çıktı karşılaştırılır. Karşılaştırılan çıktılar arasındaki fark hata olarak alınır. Öğrenme süreci ağ eğitilip istenen istatistiksel doğruluk elde edilinceye kadar devam eder. Hataların en aza indirilmesi ağırlık değerlerinin yeniden düzenlenmesi ile sağlanır. Bu model bir öğrenmede yapay sinir ağlarının dışarıdan etki ile eğitilmesi söz konusudur.

Genelleştirilmiş delta kuralı ve geri besleme algoritması danışmalı öğrenme metoduna örnek olarak verilebilir. Şekil.2.25 'de danışmalı öğrenme görülmektedir.



Şekil 2.25. Danışmalı öğrenme

Bu öğrenme yönteminde öğrenmeye dışarıdan müdahale eden bir öğretmen vardır. Öğrenme eğitici kontrolündedir. Öğretmen, eğitim kümesini ve hata değerini belirleyerek eğitimin ne kadar devam edeceğine karar verir. Bu yöntemin en önemli özelliği eğitim esnasında gerçek giriş, çıkış değerlerin kullanılmasıdır. Danışmalı öğrenme kuralları şunlardır [76]:

- 1) Perceptron Öğrenme Kuralı
- 2) Delta Öğrenme Kuralı
- 3) Genişletilmiş Delta Öğrenme Kuralı
- 4) Geri Yayılımlı Öğrenme Kuralı

2.4.4.2.1.1. Geri Yayılımlı Öğrenme Kuralı

Geri yayılımlı öğrenme kuralını kullanan ağlar hiyerarşik yapıdadır. Giriş, çıkış ve en az bir tane gizli katmandan oluşurlar. Geri yayılım öğrenme kuralı çok katmanlı ağlarda kullanılan delta kuralının genelleştirilmiş halidir. Geri yayılım ağında hatalar, ileri besleme aktarım işlevinin türevi tarafından, ileri beslemeli ağlar için kullanılan bağlantılar yardımıyla geriye doğru yayılırlar. Öğrenme işlemi, basit çift yönlü hafıza birleştirmeye dayanır [110].

Geri yayılımlı öğrenme yöntemi, türevi alınabilir etkinlik işlevi kullanılarak herhangi bir ağı uygulanabilir. Bu yöntemde geriye doğru ağırlık ayarlamaları yapıldığı için “geri yayılım” olarak isimlendirilmiştir.

2.4.4.2.1.1.1. Geri Yayılım Algoritması

Geri yayılım özel bir öğrenme kuralıdır. Bununla birlikte, bu terim genellikle geri yayılım algoritması kullanan bir ağ mimarisi ifade etmek için kullanılır. Geri yayılım algoritması mevcut çıkışlardaki hata oranlarına göre katmanların ağırlıklarını günceller. Şekil 2.26 a’da gösterildiği gibi bir geri yayılımlı yapay sinir ağı işlem hücresi; girdi tabakası, gizli tabaka ve çıktı tabakası olmak üzere en az üç tabakadan oluşur. Birden fazla gizli tabaka, bazı uygulamalar içinde kullanılabilir. Bu gizli katmanların varlığı ağı, ağ katmanları arasında daha karmaşık işlemler yapmasına ve sunmasına izin verir. Girdi tabakasının nöron sayısı girdi sayılarına eşittir. Bu nöronlardan her biri bir girdiye karşılık


gelir. Çıktı katmanı C deki çıkış nöronları çıktı ağını oluştururlar. Gizli nöron B deki katman sayısı ağı tasarımcısının takdirine bağlıdır [9].

Çok katlı perseptronların eğitilmesi için Geri Yayılma Algoritması kullanılır. Bu algoritma her öğrenme iterasyonundan sonra hataya göre ağırlıklarının değiştirilmesi ana prensibine dayanır [111].

Genellikle şekil 2.26 b de görüldüğü gibi inşaat mühendisliği uygulamalarında ifade 2.30 da belirtilen sigmoid fonksiyonu transfer fonksiyonu olarak kullanılır.

$$f_j = \frac{1}{1 + \exp(-\sum w_{ji}o_i + b)} \quad (2.30)$$

Bu formülde w_{ji} alt katmadaki nöron i ile üst katmandaki nöron j arasındaki bağlantı ağırlıklarıdır ve başlangıçta rastgele küçük bir değer seçilir. o_i i nöronunun çıkışıdır. b bias (sapma) değeridir. (Şekil 2.26 c)



Şekil 2.26. a) Geri yayılım ağı, b) Sigmoid fonksiyonu c) Yapay sinir ağının matematiksel modellenmesi

Daha öncede belirtildiği gibi öğrenme aşamasında ağa girilen giriş değerlerine karşılık çıkış değerleri sunulur. Uygulamada bu değerlerin ağa sunulmadan önce 0 ile 1 veya (0.1-0.9) arasında normalize edilmesi gerekir, çünkü transfer fonksiyonları genellikle çıktı değerlerini 0-1 arasında düzenler. Ağ başlangıçta doğru olamayan, kendi ağırlıklarını kullanarak daha önceden açıklandığı gibi kendi çıktı değerlerini üretir. Bu hesaplanma sonucu çıkış istenen çıkış değeri ile karşılaştırılır.

k katmanındaki herhangi bir çıktı nöronunun hatası $e_k = t_k - o_k$ ise, burada t_k ve o_k sırasıyla k katmanında istenilen çıktıyı ve gerçek çıktıyı gösterir. Toplam hata fonksiyonu denklem 2.31 da verilmiştir.

$$ER = \frac{1}{2} \sum_{k=1}^p e_k^2, \quad (2.31)$$

Burada p verilerin (değerlerin) sayısıdır. Öğrenme hata fonksiyonunu gradyant azalma biçiminde minimize etmek için ağırlıkların değişiminden oluşur. Geri yayılma aşamasında, ağın çıktısıyla istenen çıktı değerleri arasındaki hata genellikle delta kuralı kullanılarak hesaplanır ve nöronlar ve bias değerleri arasındaki ağırlıklar çıkış katmanından giriş katmanına denklem (2.32) ile güncellenir.

$$w_{n+1} = w_n - \eta g_n + \beta(w_n - w_n - 1) \quad (2.32)$$

Burada n iterasyon sayısıdır, η ve β sırasıyla öğrenme oranı parametresini ve momentum faktörünü belirtir. Denklem 2.32 de ki g_n geçerli gradyan vektörüdür ve çıktı katmanında ve diğer katmanlarda hata fonksiyonunun kısmi türevi kullanılarak hesaplanabilir. Yine de genel delta algoritması pratikte oldukça yavaştır. Bu nedenle Quasi-Newton ve Levenberg-Marquardt tarafından geliştirilen ölçeklendirilmiş konjuge gradyan yöntemi olarak bilinen daha hızlı algoritmalar kullanılır. Levenberg-Marquardt metodu ağın ağırlık ve bias değerlerini denklem (2.33) ile günceller.

$$w_{n+1} = w_n - (F^T F + \mu I)^{-1} F^T + e_n, \quad (2.33)$$

Burada F Jacobian matrisidir, I birim matrisidir ve e ağ hata vektörüdür. μ parametresi eğitim algoritması davranışını kontrol eden bir skalerdir. Bu μ değerinin azalışı ile birlikte algoritmada gradyan azalması meydana gelir.

Yapay sinir ağıları geri yayılım algoritmasında, ağın performansı genellikle ağın karesel ortalama hatasında göre ölçülür.

$$MSE = \frac{1}{pC} \sum_i^p \sum_k^C (t_{ik} - o_{ik})^2 \quad (2.34)$$

Burada p ve C sırasıyla veri sayısı ve çıkış düğümleridir. Ve t ve o hedef çıktıyı ve gerçek ağ çıktısını belirtiyor.

Yapay sinir ağıları geri yayılım algoritmasında, aynı katmandaki nöronlar arasında hiçbir bağlantıya izin verilmez. Ancak, bir katman üzerindeki her bir nöron bir sonraki katmandaki her bir nörona bir giriş sağlar. Geri yayılım ağı denetimli öğrenmeyi kullanır, bu yüzden giriş ve çıkış verilerinin önceden bilinmesi gerekir [77].

Geri yayılım ağında gizli katmandaki düğüm sayısı değişebilir. Düğüm sayısı artarsa ağın hatırlama yeteneği artar, ancak öğrenme süresi uzar. Düğüm sayısı az olursa öğrenme süresi kısalmış ancak ağın hatırlama yeteneği azalır [97].

Geri yayılım algoritması ağın gerçek çıkışları ile elde etmek istediğimiz çıkışlar arasındaki hataların karelerinin toplamının en aza indirilmesi ile ağın ağırlıklarının yeniden düzenlenmesi olarak genelleştirilebilir. Geri yayılım, girişlerin yanında istenen çıkışların da bulunduğu ağlarda danışmalı öğrenme kuralı olarak kullanılır. Önce öğrenmede, ağ ağırlıkları rasgele seçilir ve yeni girişler için çıkış değerlerinin hesaplanması amacıyla kullanılır. İleri besleme işlemi giriş katmanına gelen verilerin ilk gizli katmana giriş olarak aktarılmasında geçerlidir.

Geri yayılım öğrenme yöntemi, türevi alınabilir özelliğe sahip olan etkinlik fonksiyonunu çok katmanlı herhangi bir ağa uygulayabilir. En çok kullanılan algoritmadır. Bu algoritma ile çok katmanlı ağlarda öğrenme olayını gerçekleştirilir. Bu sayede önceden başarı elde edilememiş olan giriş-çıkış tasvirleri, sınıflandırma ve genelleme gibi problemlere daha iyi çözümler getirilmesi sağlanmıştır. Bu ağda iki türlü bağlantı vardır. Birinci ileri yönlü bağlantıdır ve ağırlıklar kullanılarak girişlere karşılık çıkışlar elde edilir. İkinci bağlantı geriye doğrudur ve elde edilen bu çıkışlarla beklenen çıkışlar arasındaki hata değerinin geriye yayılmasını sağlar. Bu işlem tüm katmanlar için yapılır. Tüm ağlarda olduğu gibi burada da amaç en iyi çıkışa ulaşabilmek için en uygun ağırlık değerlerini belirlemektir. Toplam hata en aza indirilinceye kadar bu işleme devam edilir [98].

2.4.4.2.2. Danışmasız Öğrenme

Herhangi bir danışmana ihtiyaç duymayan bir sistem olduğundan dolayı bu ismi almıştır. Sınıflandırma problemlerinde daha çok kullanılan bir modeldir. Bu sistemde hedef çıktı değerleri verilmediği için yapay sinir ağı parametreler arasındaki ilişkileri giriş verilerine göre kendi kendine öğrenir. Yapay sinir ağı aldığı bilgileri kendi içerisinde kıyaslama yaparak sınıflandırır. Bu metot geliştirilmeye çalışılan, sürekli araştırma yapılan bir metottur. Fakat sınırlı bir halde kalmıştır.

2.4.4.2.3. Destekleyici Öğrenme

Öğrenme metodunda giriş değerlerine karşılık çıkışın bilinmesine gerek yoktur. Bu öğrenme kuralında yapay sinir ağına sadece girdiler verilmekte, bu girdilere karşılık çıktıları üretmesi beklenmekte ve bu çıktıların ne derece doğru olduğunu belirten bir skor veya derece bildirilmektedir. LVQ ağıları bu öğrenme tipini kullanan ağlara örnek gösterilebilir.

2.4.5. Yapay Sinir Ağları Temel Öğrenme Kuralları

Yapay sinir ağları modellerinin eğitilmesinde kullanılan pek çok öğrenme algoritması bulunur. Bu algoritmalar, yapay sinir ağının topolojisine, karşılaşılan problemin niteliğine göre farklılıklar gösterse de birçoğunun temel aldıkları öğrenme kuralı Hebb Kuralı ve onun geliştirmiş versiyonlarıdır.

Bunun yanında, farklı öğrenme kuralları da vardır ve bu konuda çalışmalar sürmektedir. Temel olarak 4 öğrenme kuralından bahsedilebilir. Bunlar Hebb Kuralı, Hopfield Kuralı, Delta Kuralı ve Kohonen Kuralıdır.

2.4.5.1. Hebb Kuralı

Hebb (1949) tarafından ve biyolojik öğrenme temel alınarak geliştirilen bu kural bilinen en eski öğrenme kuralıdır [113]. Diğer öğrenme kurallarına da temel olan Hebb Kuralı'na göre, bir yapay sinir hücresi diğer bir yapay sinir hücresinden girdi alırsa ve her iki hücre de yüksek derecede aktif ise (matematiksel olarak aynı işareti taşıyorsa) her iki hücrenin arasındaki bağlantının ağırlığı artırılmalıdır.

2.4.5.2. Hopfield Kuralı

Hopfield Kuralı, bir farklılık dışında Hebb Kuralına benzer. Bu farklılık, Hopfield Kuralı'nda bağlantı ağırlığında yapılacak olan değişikliğin büyüklüğünün de belirlenmesidir [114]. Buna göre, girdi ve istenilen çıktının ikisi de aktifse, bağlantı ağırlığı öğrenme katsayısı kadar arttırılmakta, aksi durumda ise öğrenme katsayısı kadar azaltılmaktadır. Öğrenme katsayısı genel olarak 0-1 arasında tasarımcı tarafından atanan sabit ve pozitif bir değerdir.

2.4.5.3. Delta Kuralı

Widrow ve Hoff tarafından geliştirilen bu kural Hebb Kuralının gelişmiş şeklidir. En çok kullanılan kurallardan biri olan Delta Kuralı, yapay sinir hücresinin gerçek çıktısı ile beklenen çıktısı arasındaki farkı azaltmak için yapay sinir ağlarının işlemci elemanları arasındaki bağlantı ağırlık değerlerinin sürekli değiştirilmesi ilkesine dayanır. Bu kuralla, gerçek çıktı ile beklenen çıktı arasındaki hatanın karesi en aza indirilmeye çalışılmaktadır. Bu nedenle En Küçük Kareler Kuralı (Least Mean Square Rule-LMS) olarak da adlandırılır. Ayrıca bazı kaynaklarda Widrow-Hoff Kuralı olarak da geçer [86].

2.4.5.4. Kohonen Kuralı

Kohonen (1982) tarafından geliştirilen bu öğrenme kuralı biyolojik sistemlerdeki öğrenmeden esinlenilmiştir. Bu kuralda işlemci elemanlar, ağırlıklarının ayarlanması (öğrenme) için yarışmaktadırlar. Kazanan işlemci elemanın bağlantı ağırlıklarını değiştirmektedir. En uygun çıktıya sahip işlemci elemanın kazandığı kuralda bu işlemci eleman, kendisine komşu işlemci elemanların ağırlıklarının değiştirilmesine de izin vermektedir [86].

2.4.6. Levenberg-Marquardt Algoritması

Geriye yayılım algoritması, yapay sinir ağlarında en çok kullanılan algoritmadır. Geriye yayılım öğrenmesi sırasında ağ, her giriş örüntüsünü, çıkış nöronlarında sonuç üretmek üzere gizli katmanlardaki nöronlardan geçirir. Daha sonra çıkış katmanındaki hataları bulabilmek için, beklenen sonuçla, elde edilen sonuç karşılaştırılır. Bundan sonra, çıkış hatalarının türevi çıkış katmanından geriye doğru gizli katmanlara geçirilir. Hata

değerleri bulunduktan sonra, nöronlar kendi hatalarını azaltmak için ağırlıklarını ayarlar. Ağırlık değiştirme denklemleri, ağıdaki performans fonksiyonunu en küçük yapacak şekilde düzenlenir.

İleri beslemeli ağlarda kullanılan öğrenme algoritmaları, performans fonksiyonunu en küçük yapacak ağırlıkları ayarlayabilmek için, performans fonksiyonunun gradyenini kullanırlar. Geriye yayılım algoritması da, ağ boyunca gradyen hesaplamalarını geriye doğru yapar. En basit geriye yayılım öğrenme algoritması gradyen azalması algoritmasıdır. Bu algortmada ağırlıklar, performans fonksiyonunun azalması yönünde ayarlanır. Fakat bu yöntem, pek çok problem için çok yavaş kalmaktadır. Bu algortmadan daha hızlı, daha yüksek performanslı algortmalar da vardır.

Hızlı algortmalar genel olarak iki kategoriye ayırabiliriz. İlk kategorideki algortmalar, deneme yanılma tekniklerini kullanarak, standart gradyen azalması (steepest descent) yönteminden daha iyi sonuçlar verebilir. Deneme-yanılma işlemlerini kullanan geriye yayılım algortmaları; momentum terimli geriye yayılım, öğrenme hızı değişen geriye yayılım ve esnek geriye yayılım algortmalarıdır. Hızlı algortmaların ikinci kategorisindeki algortmalar, standart sayısal optimizasyon yöntemlerini kullanır. Bu algortmalar; eşlenik gradyen öğrenme algortması, Newton öğrenme algortmaları ve Levenberg – Marquardt öğrenme algortmasıdır.

Öğrenme algortmaları, kendisinden önce geliştirilen algortmalara alternatif olarak ortaya çıkmıştır ve önceki algortmaların iyi yönlerini geliştirip, kötü yönlerini azaltmaya yönelmiştir. Levenberg – Marquardt (LM) algortması Newton metoduna bir yaklaşım olup, Newton metodunun hızıyla, adım düşme metodunun sağlamlığının bileşkesidir [103]. Levenberg-Marquardt'de amaç parametre vektörünün, amaç hata fonksiyonunun minimumdayken bulunmasıdır [102].

Eşlenik gradyen öğrenme algortmasına alternatif olarak sunulan Newton yöntemlerinde, temel adım Hessian matrisini elde etmektir. Hessian matrisi, performans fonksiyonunun ağırlıklara göre ikinci dereceden türevlerinden oluşan bir matristir. Hessian matrisi, ağırlık uzayının farklı doğrultularındaki gradyen değişimini denklem (2.35)'de gösterir.

$$H(n) = \frac{\partial^2 E(n)}{\partial w^2(n-1)} \quad (2.35)$$

Burada H Hessian matrisi, E performans fonksiyonu, w ağın sinaptik ağırlığıdır. Performans fonksiyonu, duruma göre toplam ani hata veya ortalama karesel hata olarak alınabilir. Bu çalışmada, ileri beslemeli ağların çoğunda olduğu gibi, performans fonksiyonu olarak, ortalama karesel hata kullanılmıştır.

$$E(n) = E_{ort}(n) = \frac{1}{N} \sum_{n=1}^N \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.36)$$

Burada N eğitim kümesindeki toplam örüntü sayısını, e_j hata işaretini, C ağı çıkış katmanındaki bütün nöronları içeren kümeyi göstermektedir. d_j istenen değer, y_j ağı çıkışı olmak üzere hata işareti,

$$e_j(n) = d_j(n) - y_j(n) \quad (2.37)$$

olarak bulunabilir. Hessian matrisi hesaplandıktan sonra, tersi bulunarak ağırlıklar yenilenebilir. Ancak Hessian matrisi çok karmaşık ve ileri beslemeli bir yapay sinir ağı için hesaplanması zor bir matristir. Newton yöntemlerinin içinde, ikinci dereceden türevlerin hesaplanmadan işlem yapılan bir sınıf vardır. Bu sınıftaki yöntemler, Quasi – Newton yöntemleri olarak adlandırılırlar. Quasi – Newton yöntemleri, algoritmanın her iterasyonunda, Hessian matrisinin yaklaşık bir şeklini kullanır.

Levenberg – Marquardt algoritması da Quasi – Newton yöntemleri gibi, Hessian matrisinin yaklaşık değerini kullanır. Levenberg – Marquardt algoritması için Hessian matrisinin yaklaşık değeri şu şekilde bulunabilir:

$$H(n) = J^T(n) J(n) + \mu I \quad (2.38)$$

(2.38) denklemindeki μ Marquardt parametresi, I ise birim matristir. Burada J matrisi, Jakobien matrisi olarak adlandırılır ve ağ hatalarının ağırlıklara göre birinci türevlerinden oluşur:

$$J(n) = \frac{\partial e(n)}{\partial w(n-1)} \quad (2.39)$$

(2.39) denkleminde e , ağ hataları vektörüdür. Jakobien matrisi, hesaplamada Hessian matrisinden daha kolay olduğu için tercih edilir. Ağın gradyeni,

$$g(n) = J^T(n)e(n) \quad (2.40)$$

olarak hesaplanır ve ağırlıklar (2.41) denklemine göre değiştirilir:

$$w(n+1) = w(n) - [H(n)]^{-1}g(n) \quad (2.41)$$

Marquardt parametresi, μ , skaler bir sayıdır. Eğer μ sıfırsa, bu yöntem yaklaşık Hessian matrisini kullanan Newton algoritması; eğer μ büyük bir sayı ise, küçük adımlı gradyen azalması yöntemi haline gelir. Newton yöntemleri, en küçük hata yakınlarında daha hızlı ve kesindir. Her başarılı adımdan sonra, yani performans fonksiyonunun azalmasında μ azaltılır ve sadece deneme niteliğindeki bir adım performans fonksiyonunu yükseltecekse μ artırılır. Bu yöntemle, algoritmanın her iterasyonunda, performans fonksiyonu daima azaltılır.

Genel olarak Levenberg – Marquardt algoritması yavaş yakınsama probleminden etkilenmez. Burada hedef, performans fonksiyonun en küçük yapacak ağırlık değerini bulmaktır [99-101].

2.4.7. Yapay Sinir Ağlarının İnşaat Mühendisliğinde Uygulamaları

Yapay sinir ağlarının inşaat mühendisliğinde uygulamalarına 1989 yılından itibaren başlanmıştır [104]. YSA inşaat mühendisliğinin alt dallarında; Su mühendisliğinde, trafik mühendisliğinde, yapı mühendisliğinde, çevre mühendisliğinde, deprem mühendisliğinde uygulanmaktadır. Hava durumunun tahmininde, yapılarda deprem etkisi ile oluşan çatlak ve hasarların tespitinde, zemin mühendisliğinde başarı ile uygulanmaktadır. Yapı mühendisliğinde betonarme kolon boyutunun seçimi, plakların karmaşık nümerik çözümlerinin yapay sinir ağları yardımı ile çabuk yapılmasını sağlamıştır [104]. Ayrıca yapılarda yükler ve yükler altında oluşan şekil değiştirme oranı ve yer değiştirme değerlerinin YSA ile incelemeleri yapılmıştır. Betonarme bina döşemelerinin Yapay Sinir Ağları ile maliyet analizleri ve uygun boyut seçiminin tahmini son yılda yapılan çalışmadır [105]. Sonlu eleman analizlerinde uygun mesh seçimi, tek doğrultuda çalışan kirişlerin

sonlu elemanlarla analizi YSA ile yapılmıştır [106]. Beton parametre değerlerinin YSA ile tahmini ve bu gibi bir çok çalışmalar örnek verilebilir [83].

3. BETONUN KIRILMASINDA ÇİFT-K YAKLAŞIMININ YAPAY SİNİR AĞLARIYLA MODELLENMESİ

3.1. Giriş

Yapılan deneysel çalışmalar, betonun kırılma parametreleri üzerine betonun basınç mukavemeti, su/çimento oranı, maksimum agreg a çapı ve agreg a tipinin etkili olduğunu göstermektedir [13-14]. Betonun bu malzeme özellikleri çatlak oluşması ve yayılması üzerinde önemli etkilere sahiptir ve beton mekanik davranışı kırılma mekaniği ile incelenebilir. Ayrıca betonun kırılma parametreleri çimento türü, agreg a-kum oranı, porozite ve kür koşulları gibi diğer parametrelerden de etkilenebileceği belirtilmiştir [108].

Diğer taraftan, etkili çatlak boyu a_e , numunenin geometri gibi malzeme parametrelerine bağlıdır. Bu sebeple başlangıç çatlak boyunun derinliğ e oranı (a_0/d) bu çalışmada düşünülmüştür.


Sunulan tez çalışmasında, İPM ve EÇM nin eşdeğerliliği göz önüne alınarak, betonun kırılmasında etkili olan beş parametre (agrega tipi, maksimum agreg a çapı, betonun basınç mukavemeti, su/çimento oranı ve başlangıç çatlak boyunun derinliğ e oranı) oluşturulan yapay sinir ağında giriş katmanında beş giriş nöronu tarafından temsil edilmiştir. Yapılan YSA ile bu giriş katmanındaki parametreler ile çıktı katmanını oluşturan Çift-K modelindeki K_{IC}^{ini} parametresi ve etkili çatlak boyunun derinliğ e oranı (a_e/d) arasında yapay sinir ağı tabanlı yaklaşık bir kırılma modeli elde edilmiştir.

Betonun kırılma parametrelerinin ağ tabanlı analizi için 44 adet veri seti literatürdeki toplam 193 bireysel test verilerinden üretilmiştir [87-95,117]. YSA'ların eğitilmesinde kullanılan verilerin seçimi, ağın performansının ve sistem davranışının öğrenilebilmesi için çok önemlidir [80].

3.2. Yapay Sinir Ağ Modeli

Bu çalışmada ileri beslemeli geri yayılmalı ağ algoritması kullanılmıştır. Eğitim algoritması olarak Levenberg-Marquardt algoritması tercih edilmiştir. Gizli katman ve çıktı katmanı aktivasyon fonksiyonu olarak sigmoid aktivasyon fonksiyonu kullanılmıştır.

YSA mimarisini genel görünüşü aşağıdaki şekil 3.1'deki gibidir. Giriş tabakasında beş adet nörona, gizli tabakada 3 adet nörona ve çıkış tabakasında 2 adet nörona sahiptir. İki bias nöronu gizli katmana ve çıktı katmanına bağlıdır. Her bir bias değeri 1 sabit değerine sahiptir. Literatürde uygun değer gizli katman sayısını ve her bir gizli tabakadaki nöronların uygun değer sayısını belirlemek için genel bir formül yoktur. Pek çok araştırma herhangi bir mühendislik probleminin yapay sinir ağlarında bir veya iki gizli tabaka ile simüle edilebileceğini göstermiştir. Ancak iki veya daha fazla sayıda gizli tabaka veri sayısının sınırlı sayıda olduğu zaman kullanılabilir, yoksa ağda yakınsama problemi olabilir [14].



Şekil 3.1. Çalışmada oluşturulan yapay sinir ağı yapısı

3.3. Yapay Sinir Ağı'nın Eğitilmesi ve Test Edilmesi

Bu çalışmada MATLAB 7.0 programı kullanılmıştır. Uygulamada, mevcut veri seti genellemeyi iyileştirmek için eğitim seti, doğrulama seti ve test seti olarak üçe ayrılmıştır. Eğitim seti bias ve ağırlık değerlerini yeniden güncellemek ve ayarlamak için kullanılmıştır. Doğrulama seti ağı'nın eğitim sırasında aşırı uyuma engellenmesinde kullanılmıştır. Test seti yaygın olarak eğitim sürecinde düşünülmez, eğitilmiş ağı'nın genelleme yeteneğini değerlendirmek için kullanılmıştır.

Tablo 3.1 Yapay sinir ağı'nın eğitim seti

Agg. Type	$d_{\max}$ [mm]	f'_c [MPa]	w/c	a_0/d	a_e/d	K_{Ic}^{ini} [MPa $\sqrt{m}$]	Ref No.
R	2	44.3	0.5	0.2	0.267	0.408	[88]
R	2	44.3	0.5	0.4	0.444	0.411	[88]
R	2	44.3	0.5	0.6	0.626	0.405	[88]
R	5	42.1	0.5	0.3	0.366	0.389	[88]
R	5	42.1	0.5	0.5	0.547	0.363	[88]
R	10	40.3	0.5	0.3	0.376	0.378	[88]
R	14	40.9	0.5	0.3	0.382	0.334	[88]
R	20	38	0.5	0.2	0.293	0.309	[88]
R	20	38	0.5	0.3	0.392	0.297	[88]
R	20	38	0.5	0.4	0.489	0.28	[88]
R	20	38	0.5	0.5	0.589	0.253	[88]
R	10	29	0.6	0.5	0.553	0.5	[89]
R	10	58.9	0.4	0.3	0.365	0.528	[89]
R	10	55.5	0.48	0.3	0.364	0.703	[90]
R	8	110	0.22	0.329	0.375	1.503	[94]
R	12	68	0.4	0.5	0.559	0.675	[95]
R	12	21	0.8	0.5	0.577	0.283	[94,95]
R	19	54.4	0.5	0.3	0.369	0.604	[87]
C	8	28	0.8	0.5	0.563	0.458	[95]
C	20	26.8	0.77	0.295	0.44	0.357	[117]
C	20	39	0.64	0.296	0.44	0.513	[117]
C	20	49.4	0.5	0.295	0.436	0.55	[117]
C	20	67.5	0.36	0.293	0.43	0.561	[117]
C	20	78.2	0.2	0.293	0.416	0.912	[117]
0	2	21	0.2	0.2	0.267	0.253	min.
1	20	110	0.8	0.6	0.626	1.503	max.

Toplam 44 veri setinden 24 tanesi ağı eğitim setinde kullanılmıştır. Eğitim veri seti tablo 3.1. de gösterilmiştir. Tablo 3.1.'de ilk kolonda gösterilen R ve C terimleri sırasıyla Doğal agregayı ve kırma taş agregayı göstermektedir. Agregatürü şekil 3.1.'de gösterildiği gibi giriş katmanının ilk bölümüdür. Giriş katmanında agregatürünün tanımlanması tek bir ikili kod ile yapılmıştır, '0' doğal agregatür durumunu '1' kırma taş agregatür durumunu belirtmektedir.

Toplam 44 veri seti matlab programında Ek-1 de verildiği gibi 'patt' isimli değişken ile tanımlanmıştır. Bu değişkenin içerisinde çalışmada kullanılacak eğitim, doğrulama ve test verileri bulunmaktadır.

Tablo 3.1.'de gösterildiği gibi giriş vektörünü oluşturan bileşenler farklı sayısal sınırlara sahiptirler, bu nedenle YSA ya giriş ve çıkış dataları sunulmadan önce dataların normalleştirilmeleri gerekir. Eğitim ve test verilerinin ağ tarafından işlenebilmesi ve yapay sinir hücrelerinde hesaplanan toplam fonksiyonunun yaratacağı olumsuz etkileri önleyebilmek için deneysel verilerin ağ için normalize edilmesi gerekmektedir. Çünkü normalizasyon işlemi YSA performansını doğrudan etkilemektedir. Bu çalışmada, çıktıların sigmoid fonksiyonunun çıkış bölgesinde kalması için aşağıdaki eşitlik 3.1'de doğrusal normalleştirme formülü verilerin değerlerinin 0.1 ve 0.9 arasında bir değer arasında normalleştirilmesi için kullanılmıştır.

$$x_i^n = 0.1 + \frac{x_i^a - x_i^{min}}{x_i^{max} - x_i^{min}} 0.8 \quad (3.1)$$

Bu denklemde (3.1) x_i^a ve x_i^n sırasıyla giriş ve çıkış vektörlerinin normalizasyon öncesi ve sonrası i. Bileşenlerini gösterir. x_i^{min} ve x_i^{max} sırasıyla giriş ve çıkış vektörü bileşenlerinin Tablo 3.1. de son iki satırda verilen değerler normalizasyon öncesi minimum ve maksimum değerlerini gösterir.

Normalizasyon işlemi matlab programında ifade 3.2.'de verilen kodlar ile yapılmıştır. Normalizasyon işlemi sonrası veriler 'pattern' isimli değişkenle tanımlanmıştır.

```

xm= minmax(patt(1:24,;)' ');
pattern=patt';
for i=1:length(patt)
    pattern(:, i)=.1+(pattern(:,1)-xm(:, 1)). / (xm(:, 2)-xm(:, 1))*0.8 ;
end

```

(3.2)

Normalizasyon işlemi sonrasında Ek-1 de eğitim seti giriş dataları ‘p’ , çıkış dataları ‘t’ değişkenine tanımlanmıştır. Doğrulama ve test seti dataları da yine belirli değişkenlere tanımlanmıştır.

Yapay sinir hücreleri için kullanılacak aktivasyon fonksiyonunun belirlenmesinde kesin bir kural bulunmamaktadır [80]. Bu nedenle, gizli katman ve çıkış katmanındaki yapay sinir hücrelerinde kullanılan aktivasyon fonksiyonları, YSA’nın eğitiminde elde edilen en az hata değerine göre belirlenmiştir.

Geriye yayılım algoritması ileri sürümlü ağ yapısındadır. Matlab’da ileri sürümlü yapay sinir ağları newff komutu ile oluşturulur [115]. Newff komutu kullanılarak Sekil 3.1.’de gösterilen yapay sinir ağı modelinin katman sayıları, normalizasyon işlemi sonucu üretilen yeni giriş değerlerinin maksimum ve minimum değerleri, gizli katman ve çıkış katmanında kullanılacak aktivasyon fonksiyonları ve ağı eğitimi için kullanılacak öğrenme algoritması belirlenmiştir. İfade (3.3) de verilen matlab kodu ile oluşturulan ağı üç gizli ve iki çıktı nöronu olduğu, gizli katman aktivasyon fonksiyonu ve çıktı katmanı aktivasyon fonksiyonunun sigmoid fonksiyonu olduğu ve kullanılacak öğrenme algoritmasının Levenberg-Marquardt olduğu belirtilmiştir.

```

net=newff(minmax(p),[3,2],{'logsig','logsig'},'trainlm');

```

(3.3)

Kalan 20 adet veri setinden 9 data ağıdaki doğrulama setinde kullanılırken, 11 data ise çeşitli malzeme özelliklerinin ve geometrik özelliklerin doğru tahmin edilip edilmediğinin test edilmesinde faydalanılmıştır. Doğrulama seti ve test seti Tablo 3.2 ve Tablo 3.3 te sırasıyla verilmiştir.

Tablo 3.2. Yapay sinir ağıları doğrulama seti

Agg. Type	$d_{\max}$ [mm]	f'_c [MPa]	w/c	a_0/d	a_e/d	K_{Ic}^{ini} [MPa $\sqrt{m}$]	Ref No.
R	5	42.1	0.5	0.2	0.274	0.405	[88]
R	5	42.1	0.5	0.4	0.457	0.38	[88]
R	5	42.1	0.5	0.6	0.642	0.38	[88]
R	10	40.3	0.5	0.2	0.281	0.386	[88]
R	10	40.3	0.5	0.4	0.465	0.391	[88]
R	10	40.3	0.5	0.5	0.558	0.381	[88]
R	14	40.9	0.5	0.2	0.284	0.339	[88]
R	14	40.9	0.5	0.4	0.474	0.327	[88]
R	20	37.6	0.5	0.2	0.292	0.344	[88]

Tablo 3.3. Yapay sinir ağıları test seti

Agg. Type	$d_{\max}$ [mm]	f'_c [MPa]	w/c	a_0/d	a_e/d	K_{Ic}^{ini} [MPa $\sqrt{m}$]	Ref No.
R	2	44.3	0.5	0.5	0.532	0.350-0.482	[88]
R	2	44.3	0.5	0.3	0.358	0.350-0.482	[88]
R	10	58.9	0.4	0.5	0.543	0.384-0.623	[89]
R	10	55.5	0.48	0.2	0.273	0.572-0.720	[90]
R	10	55.5	0.48	0.4	0.456	0.572-0.720	[90]
R	10	55.5	0.48	0.5	0.548	0.572-0.720	[90]
R	19	53.1	0.5	0.3	0.366	0.396-0.491	[87]
R	19	54.4	0.5	0.5	0.55	0.252-0.604	[87]
R	20	36.2	0.58	0.5	0.542	0.377-0.780	[91,92]
R	20	37.6	0.5	0.4	0.485	0.309-0.365	[88]
C	8	93	0.4	0.5	0.533	0.546-0.918	[95]

Matlab programı kullanılarak 5 giriş nöronu, 2 gizli nöron ve 2 çıkış nöronundan yapay sinir ağı oluşturulmuştur. Tablo 3.4 de YSA ile ilgili parametreler verilmiştir.

Tablo 3.4. YSA ile ilgili parametreler

Girdi Tabakası nöron sayısı	5
Gizli tabaka sayısı	1
Gizli tabaka nöron sayısı	3
Çıktı tabaka nöron sayısı	2
Öğrenme döngüsü	300

Matlab programında ağıın kurulum işleminden sonra ağıın parametreleri kodlar ile belirlenmiştir. İfade (3.4) ile eğitim işlemi sırasında her bir(1) iterasyonda eğitim parametrelerinin gösterileceğı belirtilmiştir. İfade (3.5) ile eğitim işlemi hedef hataya yada minimum gradyan değeriine ulaşamaması durumunda durmazsa 300 iterasyon sonucunda duracağını ifade eder. İfade (3.6) ise hedef hata değeriinin 10^{-3} olduğunu belirtir.

net.trainparam.show=1; (3.4)

net.trainparam.epochs= 300; (3.5)

net.trainparam.goal= $1e - 3$; (3.6)

Ağıın eğitim parametreleri verildikten sonra ifade (3.7) de verilen kod ile ağıın eğitimine başlanmıştır.

[net,tr]=train(net,p,t,[],[],VV,TV); (3.7)

Ağıın giriş katmanının bias ve ağırlık değeriileri ifade (3.8) ve (3.9) ile, gizli katman ağırlık değeriileri ifade (3.10) ve (3.11) ile verilmiştir.

Bias_Input=net.b{1,1} (3.8)

Weight_Input=net.IW{1,1} (3.9)

Bias_Hidden=net.b{2,1} (3.10)


Weight_Hidden=net.LW{2,1} (3.11)

Matlab programında verilerin tanıtılması, ağıın kurulması, ağıın özelliklerinin belirlenmesi ve eğitim işleminin sonucunda ağıın ifade (3.12) ile uygun çıktıları üretmesi sağlanmıştır.

$$a=\text{sim}(\text{net},p); \quad (3.12)$$

Matlab programının son kısmında üretilen çıktılarına normalizasyon işleminin tersi uygulanmış ve çalışmada kullanılabilecek hale getirilmiştir. ‘figure’ komutu ile gerekli grafikler çizdirilmiştir.

Yapılan çalışmada YSA’nın ağırlık ve bias değerlerini güncellemek için Leventberg-Marquardt metodundan faydalanılmıştır.. İterasyon sayısı ile birlikte karesel hataların ortalamasının (MSE) varyasyonları eğitim seti, doğrulama seti ve test seti için şekil de verilmiştir. YSA eğitimini 16 iterasyon sonucunda tamamlamıştır. Geriye yayılma algoritması kullanılarak hazırlanan YSA modeli 10^{-3} hata değerinde eğitilmiş ve test edilmiştir. Bu çalışmadaki ortalama karesel hata değeri, $\text{mse} = 9,70 \times 10^{-4}$ olarak şekil 3.2. deki gibi bulunmuştur.




Şekil 3.2. Yapay Sinir ağıının iterasyona bağlı hata değişim grafiği

Yapay sinir ağının eğitilmesi ve test edilmesi sonucu Tablo 3.5'deki YSA sonuçları elde edilmiştir.

Tablo 3.5. Yapay sinir ağları test seti sonuçları


Deneysel Sonuçlar a_e/d	YSA Sonuçları a_e/d	Deneysel Sonuçlar K_{Ic}^{ini} [MPa $\sqrt{m}$]	YSA Sonuçları K_{Ic}^{ini} [MPa $\sqrt{m}$]
0.532	0.5474	0.350-0.482	0.4262
0.358	0.3494	0.350-0.482	0.4462
0.543	0.559	0.384-0.623	0.6162
0.273	0.2844	0.572-0.720	0.5001
0.456	0.4699	0.572-0.720	0.5802
0.548	0.559	0.572-0.720	0.5955
0.366	0.5723	0.396-0.491	0.5394
0.55	0.5722	0.252-0.604	0.5636
0.542	0.5753	0.377-0.780	0.3395
0.485	0.497	0.309-0.365	0.3238
0.533	0.5734	0.546-0.918	0.7348

Yapay sinir ağının K_{Ic}^{ini} deney sonuçları ile YSA sonuçları grafiği aşağıda şekil 3.3.'de verilmiştir.



Şekil 3.3. Deneysel K_{Ic}^{ini} değerleri ile YSA K_{Ic}^{ini} değerlerinin karşılaştırılması

Yapay sinir ağının a_e/d deney sonuçları ile YSA sonuçları grafiği aşağıda şekil 3.4.'de verilmiştir.



Şekil 3.4. Deneysel a_e/d değerleri ile YSA a_e/d değerlerinin karşılaştırılması

4. SONUÇ VE ÖNERİLER

Beton, yapıların inşasında en çok kullanılan yapı malzemesidir. Bu nedenle betonun mekanik davranışının tam olarak anlaşılmasının önemi her geçen gün artmaktadır. Barajlar, nükleer santraller, yüksek katlı yapılar, köprüler, tüneller vb. gibi önemli yapılarda meydana gelebilecek beton hasarları yüksek oranlarda can ve mal kaybına sebep olabilecektir. Bu sorunun incelenip, analiz edilmesi gerekmektedir.

Kırılma mekaniği, geleceğin beton tasarım ve analiz yöntemi olarak görülmektedir. Dolayısıyla betonun dayanımı ve dayanıklılığı ile ilgili tüm parametreler kırılma mekaniği açısından incelenmelidir. Bu çalışmada lineer olmayan kırılma mekaniği yöntemlerinden Çift-K modeli tercih edilmiştir.

Çift-K Modeli, beton yapılarda kırılmayı modellemek için, başlangıç gerilme şiddet çarpanı K_{ic}^{ini} ve kritik gerilme şiddete çarpanı K_{ic}^{un} gibi iki parametre kullanmaktadır. Yöntemin diğer kırılma modellerinden en önemli farkı, onların sadece çatlağın ani gelişmesini dikkate alan parametreler ile beton yapılar modellemesidir. Çift-K yönteminde ise buna ilave olarak çatlağın yayılmaya başlama kriterini de dikkate almaktadır.

Betonun malzeme parametreleri ile kırılma parametreleri arasındaki ilişki genellikle deneysel çalışmalarla belirlenmektedir. Deneysel çalışmaların çok zaman alması ve ekonomik olmaması sebebiyle son yıllarda Yapay Sinir Ağı yöntemleri geliştirilmiştir. Bu yöntemlerde önceden yapılmış deneysel çalışmalardan yararlanılmaktadır. Bu çalışmada YSA yönteminin kullanılması ile bu alandaki bu tür bir eksikliğin giderilmesi düşünülmektedir. Böylelikle betonun malzeme parametreleri ile kırılma parametreleri arasındaki ilişki daha kısa sürede elde edilmektedir.

İnsanlar, herhangi bir probleme çözüm ararken edindikleri bilgi ve tecrübeyi kullanırlar. Daha önce karşılaştıkları problemlere buldukları çözümleri ile farklı problemleri çözmede kullanabilirler. YSA larıda insan zekâsının bu özelliğinden faydalanırlar. İnsanlar gibi örneklerle eğitilen YSA lar yeterli sayıda veri grubunun kullanılması ile çok iyi sonuçlar elde edilmektedir.

Yapay Sinir Ağlarının çalışmada tercih edilmesinin en önemli sebepleri, direkt olarak örneklerden öğrenebilme yetenekleri, eksik verilerle doğru bilgiyi çıkarması ve

sonuçları genelleştirebilmesidir. Bu özellikleri ile YSA lar inşaat mühendisliği uygulamalarında kullanılmaktadır.

Çalışmada betonun malzeme parametreleri; agrega tipi, maksimum agrega çapı, betonun basınç mukavemeti, su/çimento oranı ve malzemenin geometrik parametresi başlangıç çatlak boyu (a_0) ile etkili çatlak boyu a_e ve Çift-K modelindeki başlangıç gerilme şiddet çarpanı faktörü K_{Ic}^{ini} kırılma parametreleri arasında yapay sinir ağları tabanlı bir ilişki kurulması amaçlanmıştır. Girdi setindeki malzeme parametreleri yapılan deneylerin incelenmesi sonucu belirlenmiştir. Bu çalışma ile deneysel veriler kullanılarak eğitilen bir yapay sinir ağının, matematiksel modellerle çözülen malzeme davranışına alternatif bir yol olduğu anlatılmıştır.

Çalışma esnasında seçilen ağ türünün yanı sıra çıkışların doğruluğunu etkileyen birçok faktör olduğu görülmüştür. Bunlar; öğrenme katsayısı, momentum katsayısı, ara katman sayısı, ara katmanlardaki nöron sayısı ve iterasyon sayısıdır. Sonuçta bu uygulama için en uygun sonucu elde edilecek şekilde bu faktörlerin değerleri belirlenmiş ve çalışmada sunulmuştur.

Deneysel çalışma yapmaksızın betonun kırılma parametreleri ile betonun malzeme parametreleri arasında ilişki kurulabileceğinin mümkün olduğu gözlenmiştir. Yapay sinir ağları kullanılarak birden fazla hesaplama yönteminin kullanıldığı problemlerde ve sadece ampirik yaklaşımlarla çözümü olan problemlerde kolaylık sağladığı görülmüştür.

İhtiyaç olduğu zamanda bir defa eğitilmiş bir yapay sinir ağının, girdi verileri seti verilen bir grup için gerekli çıkış sonuçları hemen anında üreteceği görülmüştür. Bu da YSA kırılma mekaniği ile ilgili çalışmalarda zaman alıcı sorunların çözümü için ve ekonomik yönden önemli bir potansiyele sahip olabileceğini göstermiştir. Böylelikle yapay sinir ağlarının inşaat mühendisliği problemlerinin çözümünde uygun olduğu açıklanmıştır.

KAYNAKLAR

1. **Griffith, A. A., (1920).** The Phenomena of Rupture and Flow in Solids. Phil. Trans. Roy. Soc., A (221), 163-198.
2. **Kaplan, M. F., (1961).** Crack Propagation and the Fracture of Concrete. Journal of ACI, 58, 591- 610.
3. **Kesler, C. E. , Naus, D. J. , Lott J. L., (1971).** Fracture Mechanics Its Applicability to Concrete.The Society of Material Science, 4, 113-124.
4. **Hillerborg, A. , Modeer, M., Petersson, P. E., (1976).** Analysis of Crack Formation and Growth in Concrete by Means of Fracture Mechanics and Finite Elements. Cement & Concrete Research, 6, 773-782.
5. **Bazant, Z. P., Oh, B. H., (1983).** Crack Band Theory for Fracture Concrete. Materials & Structures (RILEM), 16(93), 155-157.
6. **Jenq, Y. S., Shah, S. P., (1985).** A Two-Parameter Model for Concrete”, Journal of Engineering Mechanics- ASCE, 111, 1227-1241.
7. **Nallathambi, P., Karihaloo, B. L., (1986).** Determination of the Specimen Size Independent Fracture Toughness of Plain Concrete. Magazine of Concrete Research, 38, 67-76.
8. **Bazant, Z. P., Kazemi, M. T., (1990).** Determination of Fracture Energy, Process Zone Length, and Brittleness Number from Size Effect with Application to Rock and Concrete.International Journal of Fracture, 44 (2), 111- 131.
9. **Arslan, A. and İnce, R., (1996).** Neural Network-Based Design of Edge-Supported Reinforced Concrete Slabs. Structural Engineering Review, Vol. 8, No. 4, pp. 329-335

10. **Xu S. and Reinhardt, H. W., (1999).** “Determination of double-K criterion for crack propagation in quasi-brittle fracture, Part I: Experimental investigation of crack propagation”, International Journal of Fracture, Vol. 98, p. 111-149.
11. **Xu S. and Reinhardt, H. W., (1999).** “Determination of double-K criterion for crack propagation in quasi-brittle fracture, Part II: Analytical evaluating and practical measuring methods for three-point bending notched beams”, International Journal of Fracture, Vol. 98, p. 151-177.
12. **İnce, R., (2010).** “ Betonun kohezif gerilme şiddet çarpanının hesabı için basit bir yöntem”, Fırat Üniversitesi Mühendislik bilimleri Dergisi, Vol. 22,p. 215-223.
13. **Bazant Z. P. and Becq-Giraudon E., (2002).** “Statistical prediction of fracture parameters of concrete and implications for choice of testing standard”, Cement and Concrete Research, Vol. 32, p. 529-556.
14. **İnce, R., (2010).** “Artificial Neural Network-Based Analysis of Effective Crack Model in Concrete Fracture”, Fatigue and Fracture of Engineering Materials and Structures, Vol. 33, p. 595-606.
15. **Aran, A., (1981).** “ Kırılma Mekaniğine Giriş”, Seminer notları. Tübitak Marmara Araştırma Merkezi.
16. **Yayla, P., (2005).** “Kırılma mekaniği”, Kocaeli Üniversitesi Mühendislik Fakültesi Makine Mühendisliği Bölümü,1-96.
17. **Gjorv, O. E., Sorensen, S. I., and Arnesen, A., (1977).** Notch sensitivity and fracture toughness of concrete, Cement Concr. Res, 7, 333-344, .
18. **Galilei, G., (1933).** Discorsi e dimostrazioni matematiche intorno a due nuove scienze, Elzevirii, Leida, 1638. (English translation, two new sciences, The Macmillan Company, N. Y..

19. **Coulomb, C. A., (1776).** Remarque sur la rupture des corps, Memories presentes par divers savants al'Academie, vol 7.
20. **Inglish, C. E., (1913).** Stresses in a plate due to the presence of cracks and sharp corners, transactions of the Institue of Naval Architects, Vol. 55, pp. 219-241.
21. **Zener, C., and Holloman, J.H., (1944).** "Effect of Strain Rate upon Plastic Flow of Steel,"J. App L Phys., 15, 22-32.
22. **Özdemir, A., (2006).** Seramik Malzemelerin Kırılma Tokluğu Değerlerinin Üç Boyutlu Sonlu Elemanlar Yöntemi ile Teorik Olarak Belirlenmesi. Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İzmir.
23. **Irwin, G. R., (1957).** Analysis of stresses and strains near the end of a crack traversing a plate, J. Appl. Mech., 24, 361-364.
24. **Barenblatt, G. I., (1959).** On equilibrium cracks forming during brittle fracture, (Rusça) Prikladnaya Matematika i Mekhanika (PMM), 23, 434-444.
25. **Dugdale, D. S., (1960).** Yielding of steel sheets containing slits, J. Mech. Phsy. Solids, 8, 100- 104.
26. **Bilby, B. A., Cottrell, A. H., and Swinden, K. H., (1963).** The spread of plastic yield from a notch, Proc Roy Soc London, A272, 304-314.
27. **Rice, J. R., (1968).** A path independent integral and the approximate analysis of strain concentrationby nothces and cracks, J. of Applied Mechanics, June.
28. **Hillerborg, A., (1985).** Influence of beam size on concrete fracture energy determined according to a draft RILEM recommendation, Report TVBM-3201, Div Bldg Mater. Lund Inst. Tech, Sweeden,.

29. **Carpinteri, A., (1994).** Scaling laws and renormalization groups for the strength and toughness of disordered materials, *Int. J. Solids Struct*, 31, 291-302.
30. **Yılmaz, S., (2010).** Yüksek lisans tezi. Çok yüksek molekül ağırlıklı polietilenin hidrotermal yaşlandırma etkisi altındaki kırılma davranışı, Kocaeli.
31. **Alyamaç, K. E., (2004).** “Betonun Kırılma Parametreleri Üzerine Malzeme Parametrelerinin Etkisi” Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elazığ.
32. **ACI Report 446.1R.91 (1989).** Fracture Mechanics of Concrete: Concepts, Models and Determination of Material Properties, Am. Conc. Ins., Detroit.
33. **Shah, S.P., Swartz, S.E., Ouyang, C. (1995).** Fracture Mechanics of Concrete: Applications of Fracture Mechanics to Concrete, Rock and Other Quasi-Brittle Materials, John Wiley & Sons, Inc, 552 pp.
34. **Jan, G. M, Van M., (2000).** “Fracture Processes of Concrete,” CRC Pres, New York, 208p.
35. **Gör, M., (2011).** “Beton Küp Numunelerinin Diyagonal Yarmada-Çekme Yükleme Altında Boyut Etkisinin Lineer Olmayan Kırılma Mekaniği Prensipleriyle İncelenmesi,” Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elazığ.
36. **Canan, F., (1987).** “Açılı yüzey çatlaklı cam epoksi kompozit malzemelerin kırılma davranışları”, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, 16-28, Konya, (2007).
37. **Bazant, Z. P., and Pfeiffer, P A., (1987).** Determination of fracture energy properties from size effect and brittleness number, *ACI mater. J*, 84, 463-480

38. **Shah, S. P., and Tasdemir, M. A., (1994).** “Role of Fracture Mechanicsin Concrete Technology”, Advances in Concrete Technology, (ed. V. M. Malhotra), CANMET, Second Edition, 161-202, 1994.
39. **Belgin, Ç. M., (1997).** Beton Kolonların Göçme Yüklerinde Boyut Etkisi, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
40. **Belgin, Ç. M., (2004).** Aşırı Donatılı Betonarme Kirişlerde Boyut Etkisi Deneyleri Doktora Tezi, Gazi Üniv., Fen Bilimleri Enstitüsü, Ankara, 2004.
41. **Quyang, C., Taşdemir, M. A., Shah, S.P (1996).** Fracture Mechanics of concrete composites.” Proc. CMD8, June 11-16, Varna, Ed. K.Z. Markov, World Scientific Publishing Company, 639-645.
42. **Yeğınobalı A., Tokyay M., (1981).** Betonun Kırılma Mekanığı Konusundaki Çalışmaların Değerlendirilmesi, Birinci Ulusal Kırılma Konferansı, Ankara.
43. **Glucklich, J., (1963).** Fracture of plain concrete, ASCE J. Engng. Mech, 89, 127-138.
44. **Romualdi, J. P., and Batson, G. B., (1963).** Mechanics of crack arrest in concrete, ASCE J. Engng. Mech, 89, 147-168.
45. **Zaitsev, Ju, V., (1971).** Deformation and failure of hardened cement paste and concrete subjected to short term load, Cement Concr. Res, 1, 123-137.
46. **Swamy, R. N.. and Rao C. K., (1973).** Fracture mechanism in concrete systems under uniaxial loading, Cement Concr Res, 3, 413-427.
47. **Brown, J. H., (1972).** Measuring the fracture toughness of cement paste and mortars, Cement Concr. Rec, 3, 475-480.

48. **Shah, S. P., and McGarry, F. J., (1971).** Griffith fracture criterion and concrete, ASCE J. Engng. Mech, 97, 1663-1676.
49. **Walsh, P. F., (1972).** Fracture of plain concrete, Indian Concr. J, 46, 469-470.
50. **Higgins, D. D., and Bailey, J. E., (1976).** Fracture measurements on cement paste, J. Mater Sci, 1.
51. **Mindess, S., and Nadeau, J. S., (1976).** Effect of notch width on KIC for mortar and concrete, Cement Concr. Res, 6, 529-534.
52. **Walsh, P. F., (1976).** Crack initiation in plain concrete, Mag. Concr. Res, 28, 37-41.
53. **Rossi, P., Acker, P., and Francois, D., (1984).** Measurements of the fracture toughness K_{Ic} of concrete, In fracture' 84, Eds. Valluri, S R et. al., Pergamon Press, Oxford, 4, 2833-2839.
54. **Ohgishi, S., Ono, H., Takatsu, M., and Tanahashi, I., (1986).** Influence of test conditions on fracture toughness of cement paste and mortar, In G-23, 281-290.
55. **Tian, M., Huang, S., Liu, E., Wu, L., Long, K., and Yang, Z., (1986).** Fracture toughness of concrete, In G-23, 299-306.
56. **Karihaloo, B. L. and Nallathambi, P. (1990).** Effective crack model for the determination of fracture toughness . K_{SIc} / of concrete. Engineering Fracture Mechanics 35(4/5), 637-645.
57. **Refai, T. M. E. and Swartz, S. E. (1987).** Fracture Behavior of Concrete Beams in Three- Point Bending Considering the Influence of Size Effects. Report No. 190, Engineering Experiments Station, Kansas State University.

58. **Bazant, Z.P., Kim, J.K. and Pfeiffer, P.A. (1986).** Determination of fracture properties from size effect tests. *Journal of Structural Engineering*. ASCE, 112 (2), 289–307.
59. **RILEM Recommendation (1990a).** Determination of the fracture parameters (K_{Ic}^S and $CTOD_c$) of plain concrete using three-point bend tests. *Materials and Structures*. 23(138), 457-460.
60. **RILEM Technical Committee 50-FMC (1985).** Determination of the fracture energy of mortar and concrete by means of three-point bend tests of notched beams, proposed RILEM draft recommendations. *RILEM, Materials and Structures* 18(106), 285–296.
61. **RILEM Technical Committee 89-FMT (1990b).** Size-effect method for determining fracture energy and process zone size of concrete, proposed RILEM draft recommendations. *Ibid.* 23(138), 461–465.
62. **Taşdemir, M. A., Bayramov, F., Akkaya, Y., (2003).** Betonun Kırılma Mekanîği: Tasarımda Kullanılan Mekanik Özellikler İle Kırılma Parametreleri Arasındaki Bağlılıklar. *Türkiye Mühendislik Haberleri Sayı 426*, İTÜ, İnşaat Fakültesi, İstanbul.
63. **Bache, H. H., (1986).** In *Fracture Toughness and Fracture Energy of Concrete*, Wittmann, F.H., Ed. Elsevier Science Publishers: Amsterdam, 577-586.
64. **Hillerborg, A., (1983).** Analysis of a single crack, In *Fracture Mechanics of Concrete*, ed. F.H. Wittmann, Elsevier, Amsterdam, pp. 223-249.
65. **Brühwiler, E., Broz, J. J., and Saouma, V. E., (1991).** Fracture model evaluation of dam concrete, *J.Mater . Civil Engng*, 3, 235-251,
66. **Karihaloo, B. L., (1995).** “Fracture Mechanics and Structural Concrete”, Longman Group Ltd., Essex, England

67. **Shah, S. P., Ouyang, C., (1992).** Measurement and Modelling of Fracture Processes in Concrete, in Materials Science of Concrete, Scalny, J. (Ed.), The American Ceramic Society, Ohio, 3, 243-270
68. **Tada, H., Paris, P. C., Irwin, G. R. (2000).** The Stress Analysis of Cracks Handbook. ASME Press.
69. **CEB-Comite (1993).** Euro-International du Beton- EB-FIP Model Code 1990, Bulletin D'Information No. 213/214, Lausanne.
70. **Tang, T., Ouyang, C. ve Shah, S. P., (1996).** A Simple Method for Detemining Material Fracture Parameters from Peak Loads, ACI Materials Journal, 93 (2), 147-157.
71. **Jenq Y. S., Shah, S. P. (1985b).** A fracture toughness criterion for concrete. Engineering Fracture Mechanic. 21(5), 1055–1069.
72. **İnce, R., (1998).** “Betonarme yapı elemanlarında basınç-kesme kırılmasının ve boyut etkisinin deneysel ve nümerik olarak incelenmesi”, Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, 140s.
73. **Ülker, M., Civalek, Ö., (2002).** Yapay Sinir Ağları ile Eksenel Yüklü Kolonların Burkulma Analizi, Turkish J. Eng. Env. Sci., 117-125.
74. **Bildik, A. T., (1998).** “Normal Basınç Dayanımlı Beton Karışımlarının Yapay Sinir Ağları ile Hesaplanması” Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elazığ.
75. **Vanluchene, R. D., Roufei, S., (1990).** Neural Networks in Structural Engineering, Microcomputers in Civil Eng., 207-215.
76. **Şen, Z., (2004).** Yapay Sinir Ağları ve İlkeleri. Su vakfı yayınları. İstanbul.

77. **Sağıroğlu, Ş., Beşdok, E., Erler, M., (2003).** Mühendislikte Yapay Zeka Uygulamaları-I: Yapay Sinir Ağları, UFUK Kitabevi, 1. Baskı, Kayseri.
78. **Caferov, O. (2005).** “Öngerilmeli betondan boşluklu plak köprülerin yapay sinir ağları ile analizi.” Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri.
79. **S.Y. Kung and K.I. (1996).** Diamantaras, Principal Component Neural Networks, Theory and Applications, NewYork: Jhon Wiley & Sons, s. 5-7.
80. **Özveren, U., (İstanbul 2006).** Pem yakıt hücrelerinin yapay sinir ağları ile modellenmesi. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
81. **Howard, D., Mark, B., Martin, H., (2009).** Neural Network Toolbox For Use with User’s Guide. The Math Works.
82. **Judith E. Dayhoff, (1990).** Neural Network Architectures An Introduction,, NewYork: Van Nostrand Reinhold, 1990, s. 1-6.
83. **Fairbairn, E., (2000).** M., R., Determination of Probabilistic Parameters of Concrete: Solving The Inverse Problem by Using Artificial Neural Networks, Computers and Structures 78, 497-503
84. **Yurtoğlu, H., (2005).** Yapay Sinir Ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği. Uzmanlık Tezi.Yayın No: Dpt: 2683 Ankara.
85. **Efe, Ö., Kaynak, O., (2000).** Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi Yayınları, İstanbul.
86. **Öztemel, E., (2012).** Yapay Sinir Ağları, Papatya Yayıncılık Eğitim, İstanbul.

- 87. Refai, T. M. E. and Swartz, S. E. (1987).** Fracture Behavior of Concrete Beams in Three-Point Bending Considering the Influence of Size Effects. Report No. 190, Engineering Experiments Station, Kansas State University.
- 88. Nallathambi, P. (1986).** Fracture behaviour of plain concretes, Doctoral Dissertation, University of Newcastle, Australia, p. 207.
- 89. Malvar, J.L., (1987).** Private Communication, Naval Civil Engineering Laboratory, California. See also Report from Malvar, October 1987.
- 90. Ferrara, G., (1987).** Private Communication, Italian Electricity Board (ENEL-DSR- CRIS), Milano.
- 91. Elices M., Corres, H. And Planas, J., (1987).** Experimental results of fracture energy of concrete for different specimen sizes, Report to RILEM TC 50-FMC, Madrid.
- 92. Planas, J. and Elices, M., (1986).** Towards a measure of G_f : An analysis of experimental results, Fracture Toughness and Fracture Energy of Concrete, (F.H. Wittmann, Ed.), Elsevier Science Publishers, pp. 381-390.
- 93. Jeng, Y.S. and Shah, S.P., (1984).** Non-linear fracture parameters for cement based composites: theory and experiments, Proceedings of the NATO Advanced Workshop: Application of fracture mechanics to cementitious composites, Editor: S.P. Shah, Northwestern University, pp. 213-253
- 94. John, R., Shah, S.P., and Jeng, Y.S., (1987).** A fracture mechanics model to predict the rate sensitivity of mode I fracture for concrete, Cem. And Conc. Research, V17, pp. 249- 262.
- 95. Horvath, R. And Persson, T., (1984).** The influence of the size of the specimen on the fracture energy of concrete, Report TUBM-5005, Lund, Sweden, p. 45.

- 96. RILEM (Edited by S.P. Shah and A. Carpinteri), Chapman and Hall,** Fracture mechanics test methods for concrete, Report of Technical Committee 89-FMT, 1–69.
- 97. Stamatios V. Kartalopoulos, (1995).** Understanding Neural Networks and Fuzzy Logic, New York: The Institute of Electrical and Electronics Engineers Press, s. 78-80.
- 98. Mehrotra, K., Chilukuri, K. M. And Sanjay, R., (2000).** Elements of Artificial Neural Networks, Massachusetts.
- 99. M. Oğuz, (2001).** Yalıtkan Maddelerde Elektriksel Delinme Dayanımının Yapay Sinir Ağları ile Belirlenmesi, Yüksek Lisans Tezi, İTÜ.
- 100. S. Haykin, (1999).** Neural Networks: a Comprehensive Foundation, Upper Saddle River, N.J., Prentice Hall.
- 101. S. H. Ngia, (2000).** "Efficient Training of Neural Nets for Nonlinear Adaptive Filtering Using a Recursive Levenberg-Marquardt Algorithm". IEEE Trans. on Signal Process., Vol 48, pp. 1915-1927.
- 102. Demuth, B. H., Hagan, T. M. ve Beale, M., (2002).** Neural Network Design, PWS Publishing Company, California.
- 103. Lourakis, M. I. A. (2005).** “A Brief Description of the Levenberg-Marquardt Algorithm Implemented by levmar.”, Institute of Computer Science Foundation For Research and Technology, Crete, Greece
- 104. Adeli, H., (2001).** Neural Networks in Civil Engineering: 1989-2000, Computer-Aided Civil and Infrastructure Engineering 16, 126-142.
- 105. Ahmadkhanlou, F., (2005).** Optimum Cost Design of Reinforced Concrete Slabs Using Neural Dynamics Model, Engineering Applications of Artificial Intelligence 18, 65-72,.

- 106. Hurtado, J., E., (2002).** Analysis of One- Dimensional Stochastic Finite Elements Using Neural Networks, Probabilistic Engineering Mechanics 17, 35-44, 2002.
- 107. Arslan, A. and İnce, R., (1996).** The Neural Network Approximation to the size effect in fracture of cementitious materials. Engineering Fracture Mechanics Vol. 54, No. 2 pp. 249-261.
- 108. İnce, R., (2004).** “Prediction of fracture parameters of concrete by artificial neural networks”, Engineering Fracture Mechanics, Vol. 71, p. 2143-2159.
- 109. İnce, R., (2012).** Determination of The Fracture Parameters of The Double-K Model Using Weight Functions of Split-Tension Specimens. Engineer Fracture Mechanics Vol 96 pp. 416-432
- 110. Kishan Mehrota, Chilukuri K. Mohan ve Sanjay Ranka, (1997).** Elements of Artificial Neural Networks, Londond: Massachusetts Institute of Tecnology, s. 70.
- 111. Haykin, S., (1994).** Neural Networks, A comprehensive foundation, Mc Master University, Mac Col Pub Company, New York, U.S.A.
- 112. Zurada, M.J., (1992).** Introduction to Artificial Neural Systems, West PublishingCompany, Inc. New York.
- 113. Hebb, D. O., (1949).** ‘The organization of behaviour’, New York: Wiley, Introduction and Cahpter 4, ‘The first stage of perception: growth of the assembly’, pp.xi-xix, 60-78
- 114. Hopfield J.J., (1982).** Neural networks and physical systems with emergent collective computational abilities,’Proceedings of National Academy of Science, vol. 79, (USA), pp. 2554-2558
- 115. Coskun, H., (2011).** Yapay Sinir Ağlarının Tahmin Amaçlı Kullanımı. Matlab ve Neuroslotions Uygulamalı. Ekin Yayınevi, İstanbul.

116. Demirkıran, T., (Elazığ 2011). Betonun başlangıç gerilme şiddet çarpanı kırılma parametresi üzerine betonun malzeme parametrelerinin etkisi ile Hesaplanması, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü.

117. Karihaloo, B. L. and Nallathambi, P. (1991). Notched beam test: mode I fracture toughness. In: Fracture Mechanics Test Methods for Concrete, (Edited by S.P. Shah and A. Carpinteri), RILEM, Chapman & Hall, London, pp. 1–86.

EKLER

Ek-1 Betonun Kırılmasında Çift-K Yaklaşımının Yapay Sinir Ağlarıyla Modellenmesinde Kullanılan Matlab Programı

```
clear all
%LEVENBERG-MARQUARDT ALGORITHM
%Train-Validation-Test data
%0.1-0.9 normalization
%Input Vector:[Agg.Type dmax fc w/c a0]& Output Vector:[ae Kicini]
patt=[0 2 44.3 0.5 0.2 0.267 0.408
0 2 44.3 0.5 0.4 0.444 0.411
0 2 44.3 0.5 0.6 0.626 0.405
0 5 42.1 0.5 0.3 0.366 0.389
0 5 42.1 0.5 0.5 0.547 0.363
0 10 40.3 0.5 0.3 0.376 0.378
0 14 40.9 0.5 0.3 0.382 0.334
0 20 38 0.5 0.2 0.293 0.309
0 20 38 0.5 0.3 0.392 0.297
0 20 38 0.5 0.4 0.489 0.28
0 20 38 0.5 0.5 0.589 0.253
0 10 29 0.6 0.5 0.553 0.5
0 10 58.9 0.4 0.3 0.365 0.528
0 10 55.5 0.48 0.3 0.364 0.703
0 8 110 0.22 0.329 0.375 1.503
0 12 68 0.4 0.5 0.559 0.675
0 12 21 0.8 0.5 0.577 0.283
0 19 54.4 0.5 0.3 0.369 0.604
1 8 28 0.8 0.5 0.563 0.458
1 20 26.8 0.77 0.295 0.44 0.357
1 20 39 0.64 0.296 0.44 0.513
1 20 49.4 0.5 0.295 0.436 0.55
1 20 67.5 0.36 0.293 0.43 0.561
1 20 78.2 0.2 0.293 0.416 0.912
```

```

0 5 42.1 0.5 0.2 0.274 0.405
0 5 42.1 0.5 0.4 0.457 0.38
0 5 42.1 0.5 0.6 0.642 0.38
0 10 40.3 0.5 0.2 0.281 0.386
0 10 40.3 0.5 0.4 0.465 0.391
0 10 40.3 0.5 0.5 0.558 0.381
0 14 40.9 0.5 0.2 0.284 0.339
0 14 40.9 0.5 0.4 0.474 0.327
0 20 37.6 0.5 0.2 0.292 0.344
0 2 44.3 0.5 0.5 0.532 0.408
0 2 44.3 0.5 0.3 0.358 0.398
0 10 58.9 0.4 0.5 0.544 0.542
0 10 55.5 0.48 0.2 0.273 0.671
0 10 55.5 0.48 0.4 0.456 0.637
0 10 55.5 0.48 0.5 0.548 0.595
0 19 53.1 0.5 0.5 0.552 0.396
0 19 54.4 0.5 0.5 0.55 0.497
0 20 36.2 0.58 0.5 0.542 0.613
0 20 37.6 0.5 0.4 0.485 0.309
1 8 93 0.4 0.5 0.533 0.726];
%Normalization
xm=minmax(patt(1:24,:));
pattern=patt';
for i=1:length(patt)
    pattern(:,i)=.1+(pattern(:,i)-xm(:,1))./(xm(:,2)-xm(:,1))* .8;
end
%Data p:input, t=output
p=pattern(1:5,1:24);
t=pattern(6:7,1:24);
VV.P=pattern(1:5,25:33);
VV.T=pattern(6:7,25:33);
TV.P=pattern(1:5,34:44);
TV.T=pattern(6:7,34:44);

```

```

%Network art
net=newff(minmax(p),[3,2],{'logsig','logsig'},'trainlm');
%Network parameters
net.trainparam.show=1;
net.trainparam.epochs=300;
net.trainparam.goal=1e-3;
%net.trainParam.mu_max=100
%Training
[net,tr]=train(net,p,t,[],[],VV,TV);
%Weights
Bias_Input=net.b{1,1} %Bias of Input Layer
Weight_Input=net.IW{1,1} %Weight of Input Layer
Bias_Hidden=net.b{2,1} %Bias of Hidden Layer
Weight_Hidden=net.LW{2,1} %Weight of Hidden Layer
%Train Simulation
a=sim(net,p);
a(1,:)=(a(1,:)-.1)*(xm(6,2)-xm(6,1)).8+xm(6,1);
a(2,:)=(a(2,:)-.1)*(xm(7,2)-xm(7,1)).8+xm(7,1);
t(1,:)=(t(1,:)-.1)*(xm(6,2)-xm(6,1)).8+xm(6,1);
t(2,:)=(t(2,:)-.1)*(xm(7,2)-xm(7,1)).8+xm(7,1);
a
%Regression
figure(2)
subplot(2,1,1)
[m b r]=postreg(a(1,:),t(1,:))
subplot(2,1,2)
[m b r]=postreg(a(2,:),t(2,:))
%Test Simulation
testV=sim(net,VV.P);
testV(1,:)=(testV(1,:)-.1)*(xm(6,2)-xm(6,1)).8+xm(6,1);
testV(2,:)=(testV(2,:)-.1)*(xm(7,2)-xm(7,1)).8+xm(7,1);
VV.T(1,:)=(VV.T(1,:)-.1)*(xm(6,2)-xm(6,1)).8+xm(6,1);
VV.T(2,:)=(VV.T(2,:)-.1)*(xm(7,2)-xm(7,1)).8+xm(7,1);

```

```

testT=sim(net,TV.P);
testT(1,:)=(testT(1,:)-.1)*(xm(6,2)-xm(6,1)).8+xm(6,1);
testT(2,:)=(testT(2,:)-.1)*(xm(7,2)-xm(7,1)).8+xm(7,1);
TV.T(1,:)=(TV.T(1,:)-.1)*(xm(6,2)-xm(6,1)).8+xm(6,1);
TV.T(2,:)=(TV.T(2,:)-.1)*(xm(7,2)-xm(7,1)).8+xm(7,1);
[patt(25:33,1:5) VV.T' testV';
 patt(34:44,1:5) TV.T' testT']
%Regression
figure(3)
subplot(2,1,1)
[m b r]=postreg(testV(1,:),VV.T(1,:))
subplot(2,1,2)
[m b r]=postreg(testV(2,:),VV.T(2,:))
figure(4)
subplot(2,1,1)
[m b r]=postreg(testT(1,:),TV.T(1,:))
subplot(2,1,2)
[m b r]=postreg(testT(2,:),TV.T(2,:))

```

ÖZGEÇMİŞ

Cenk FENERLİ, 1986 yılında Kelkit'te doğdu. İlk öğrenimini Atatürk İlkokulu ve Sümer Orta okulunda, orta öğrenimini Turgut Özal Anadolu lisesinde, Malatya'da tamamladı. 2004 yılında girdiği Fırat Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü'nden 2009 yılında mezun oldu. Turan ÜZMEZ mimarlık bürosunda statik proje çiziminde, EKİNCİLER İnşaat ve METROKENT Yapı denetim firması bünyesinde kontrol mühendisi olarak çalışmalarda bulundu. 2010 yılında Fırat Üniversitesi, Fen Bilimleri Enstitüsünde, İnşaat Mühendisliği, Yapı Ana Bilim Dalında Yüksek Lisans' a başladı. Yüksek Lisansı devam ederken 2012 yılı Şubat ayında İnönü Üniversitesi Hekimhan Meslek Yüksekokulunda Öğretim Görevliliğine atandı. Halen Öğretim görevlisi görevini sürdürmektedir