

1. GİRİŞ

İnsanların yüzyıllardır doğru bilgiye ulaşma isteği ve elde edilen bilgilerin işlenmesi teknolojinin gelişmesine katkı sağlamıştır. Geline bu noktada günümüz teknolojisinde bilgisayar ve bilgisayar sistemleri insan hayatının vazgeçilmezi haline gelmiştir. Bilgisayar sistemlerinden matematiksel olarak formülasyonu kurulamayan karmaşık problemlerin çözümü ve çıkan sonucun yorumlanması düşüncesi yeni hesaplama modeli olan yapay sinir ağlarının geliştirilmesine imkan sağlamıştır.

Yapay sinir ağları insanın sinir sisteminden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır (Elmas 2003). Yapay zeka, makine öğrenme ve paralel dağılımlı işlem olarak da isimlendirilen yapay sinir ağları karmaşık bir sistemdir. Yapay sinir hücreleri sahip oldukları ağırlıklarla birbiriyle bağlantılı durumdadır.

Temelinde insan beyninin taklit edilmesi gerçeği yatan yapay sinir ağları öncelikle tıp alanında kullanılmıştır (Dere 1997). Kullanım alanları giderek artan yapay sinir ağları günümüzde mühendislik uygulamalarında, finansal uygulamalarda, endüstriyel uygulamalarda, askeri uygulamalarda karmaşık problemlere çözüm üreten model olarak karşımıza çıkmaktadır.

Bilgisayar, problemin çözümü için gerekli veri girişinin yapılmasıyla kompleks problemleri bile kısa zamanda çözebilmektedir. Eldeki sahip bilgiler yardımıyla farklı problemlere çözüm üretilmesi ve yetersiz bilginin işlenmesi noktasında bilgisayarlar yetersiz kalırken yapay sinir ağları güvenli bir şekilde kullanılmaktadır. Yapay sinir ağının önemli özelliği, olayları öğrenebilmesi ve olaylar arasında ilişki kurabilme yeteneğine sahip olmasıdır. Bu özellik yapay sinir ağlarının kısa zamanda kullanım alanını artırmış ve bilgisayar sistemlerine üstün kılan alternatif bir model haline getirmiştir.

Son zamanlarda mühendislik uygulamalarında yapay sinir ağları sıkça kullanılmaktadır. Mühendislik çalışmalarında doğru ve güvenilir yöntemin kullanılarak uygun çözümün elde edilmesi gerekmektedir. Yapay sinir ağları kullanılarak yapılan çalışmalarda başarılı sonuçlar elde edilmiştir. Özellikle örüntü tanımı, işaret işleme, sistem tanılama ve doğrusal olmayan denetim

alanlarında yapay sinir ağılarının değişik modelleri ve değişik öğrenme stratejileri başarı ile kullanılmıştır (Efe ve Kaynak 2004). Mühendislik uygulamalarında doğrusal olmayan problemlerin çözümünde yapay sinir ağıları tercih edilen alternatif bir model olmuştur.

Fırat ve Güngör (2004), yapay sinir ağıları ile akarsularda askı maddesi miktarının tespitini yapmışlardır. Yapay sinir ağıları ile hesaplanan askı maddesi miktarı ve konsantrasyonu EİE tarafından yapılan ölçüm sonuçları ile mukayese edilmiştir.

Koç, Balas ve Arslan (2004), taş dolgu dalgakıranların ön tasarımı yapay sinir ağılarını kullanmışlardır. Çalışmada ileri beslemeli yapay sinir ağı ile taş dolgu dalgakıranların stabilite sayılarının tahmini yapılmıştır. Stabilite sayısı ve hasar seviyesi belirlenmeye çalışılmıştır. Mersin Yat Limanı ana dalgakıranının ön tasarımı yapay sinir ağıları ile gerçekleştirilmiştir.

Aydoğmuş ve Çöteli (2005), yapay sinir ağıları yardımı ile bir yüksek gerilim izolatörü yüzeyinde sızma aralığı üzerindeki düğüm noktaları için potansiyel tahmini yapmışlardır. Sızma aralığı üzerindeki noktalara ilişkin potansiyel değerler Fortran'da yazılmış bir program ile hesaplanmıştır. Yapay sinir ağının bulduğu değerler ile programda hesaplanan değerler karşılaştırılmıştır.

Civalek ve Çatal (2004), farklı mesnet şartları için elastik kirişlerin deplasman ve titreşim frekanslarını veren çok katmanlı yapay sinir ağı geliştirmişlerdir. Eğitim ve test setlerinde deplasman ve titreşim analizi için farklı mesnetler kullanılmıştır. Yapay sinir ağından elde edilen sayısal sonuçlar analitik yöntemle hesaplanan sonuçlarla karşılaştırılmıştır.

Baylar, Emiroğlu ve Arslan (1999), dolu gövdeli bağlamalarda ayırma duvarının etkisi dikkate alınarak yanal su alma yapısına yönelecek olan sürüntü maddesi oranının yapay sinir ağı yöntemi ile tespiti yapılmıştır. Çalışmada DSİ tarafından yapılan deneysel veriler kullanılmıştır.

Civelek ve Ülker (2004), dikdörtgen plakların doğrusal ve doğrusal olmayan analizinde yapay sinir ağı kullanmıştır. Dikdörtgen plakların orta nokta momentleri ve deplasmanları hesaplanmıştır.

Göktepe, Ağar ve Lav (2005), FWD deneyinden elde edilen defleksiyon değerlerinden yararlanılarak üst yapı tabakalarına ait mekanik özellikleri yapay sinir ağları ile geri hesaplayan bir model oluşturmuşlardır.

Alp ve Cıgızoğlu (2004), uygulamada ileri beslemeli geriye yayılım yöntemi (İBGY) ile genelleştirilmiş sinir ağı (GRSA) yöntemi kullanılarak sonuçlar seçilen performans kriterleri açısından karşılaştırılmıştır. GRSA yöntemi ile İBGY metodunun yerel minimum sorunu çözülerek tek simülasyonla değişmeyen bir sonuca ulaşılmıştır.

Keleşoğlu, Ekinci ve Fırat (2005), yalıtım malzemesinin kalınlığının tespitinde çok katmanlı ileri beslemeli yapay sinir ağı kullanılmıştır. Yapı elamanı olarak tuğla duvar seçilmiş olup yalıtım malzemesi olarak da mineral yün tercih edilmiştir.

Terzi ve Karaşahin (2004), üstyapı performansının belirlenmesi için kullanılan yöntemleri özetlenmişlerdir. Üst yapı kesimlerinin mevcut ve ileriki yıllara ait durumunun belirlenmesi amacı ile, dikkate alınan üst yapı performans göstergesindeki değişim oranının önceden tahmini gereklidir. Yapay sinir ağları ile geliştirilen bir model yardımıyla sonuçlar elde edilmiştir.

Dere (1997), yapı analizi ve tasarımındaki uygulamaları yapay sinir ağıyla incelemiştir. Çalışmada turbo pascal dilinde geliştirilen bir bilgisayar programı kullanılmıştır. Analitik yöntemle bulunan sayısal sonuçlarla yapay sinir ağından elde edilen sayısal sonuçlar karşılaştırılmıştır.

Armutcu (1997), genetik algoritmayı elik dzlem erevelere uygulamıştır. Deplasman ve sınır gerilmelerde TS 648 esas alınmıştır. rnek ereve zmleri yapılarak elde edilen sayısal sonuçlar incelenmiştir.

Bu alıřmada yapay sinir ağılarının izostatik kafes sistem analizi ve tasarımındaki uygulamalar incelenmiştir. Yapay sinir ağıının kafes kiriřlerin zm zerindeki etkinliğini arařtırmak iin beř farklı uygulama yapılmıştır. Her uygulamada sistem řekli, aıklık ve ykleme durumu farklı izostatik kafes kiriř seilmiştir. Uygulamalarda elde edilen sonuçlar tablo ve grafik olarak dzenlenmiştir. Her uygulamada oluřan hata deėerleri hesaplanarak yapay sinir ağıının izostatik kafes kiriřler zerindeki ėrenme yeteneėi arařtırılmıştır.

2.YAPAY SİNİR AĞLARI

2.1 Yapay Sinir Ağlarının Tarihçesi

İlk yapay sinir ağ modeli 1943 yılında, Warren McCulloch ve Walter Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağını modellemişlerdir (Elmas 2003). 1949 yılında Donald Hebb, yapay hücrelerden oluşan bir yapay sinir ağının değerlerini değiştiren bir öğrenme kuralı geliştirmiştir. “Hebbian öğrenme” kuralı denilen bu kural günümüzde birçok öğrenme kuralının temelini oluşturmaktadır (Öztemel 2003). 1950’li yıllardan sonra bu konu üzerinde çalışanlar özellikle Hebbian öğrenme kuralından etkilenerek yapay sinir ağlarını geliştirmeye çalışmışlardır. Frank Rosantblatt tarafından geliştirilen perceptron modeli yapay sinir ağlarında bir dönüm noktası niteliğindedir. Perceptron tek katmanlı algılayıcı olup eğitilebilen bir modeldir. Perceptron aynı zamanda çok katmanlı algılayıcıların da temel kaynağı durumundadır.


1960’lı yıllarda yapay sinir ağındaki çalışmalarda gerileme gözlenmiştir. Yapay sinir ağlarının gerilemesine Minsky ve Pappert tarafından yazılan algılayıcılar (Perceptrons) başlıklı kitap neden olmuştur. Minsky ve Pappert, yapay sinir ağlarıyla doğrusal olmayan problemlerin çözümünün mümkün olmadığını iddia ettiler. İddialarını kanıtlamak için klasik XOR probleminin çözümsüzlüğünü öne sürmüşlerdir (Öztemel 2003). Bu iddia birçok bilim adamı tarafından kabul görüp desteklenmiştir. Bu yüzden yapay sinir ağları ile ilgili çalışmalar büyük ölçüde yavaşlamıştır.

Tüm bunlara rağmen, Anderson, Wilshaw, Kanerva ve Kohonen gibi az sayıdaki yapay sinir ağ savunucuları sesiz araştırmalarına devam ettiler. Son yıllarda yapılan çalışmalarla, yapay sinir ağları her alanda yaygın olarak kullanılmaya ve başarılı sonuçlar alınmaya başlanmıştır (Elmas 2003). 1982 yılında Hopfield tarafından yayınlanan çalışmalar ile yapay sinir ağlarının genelleştirilebileceği ve özellikle geleneksel bilgisayar programları ile çözülmesi zor olan karmaşık problemlere çözüm üretebileceğini göstermiştir (Öztemel 2003).

Son yıllarda düzenlenen panel, sempozyum ve konferanslar ile yapay sinir ağıları konusunda ilerleme kaydedilmektedir. Günümüzde yapay sinir ağıları birçok meslek grubunda uygulama alanına sahip bir model olarak karşımıza çıkmaktadır.

2.2 Yapay Sinir Ağlarının Tanımı

Yapay sinir ağıları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirebilmek amacı ile geliştirilen bilgisayar programıdır (Öztemel 2003). Yapay sinir ağıları, günümüzde pek çok meslek grubunda değişik problemlerin çözümünde kullanılmaktadır. Yapay sinir ağıları yapay sinir hücrelerinden meydana gelmiştir. Bu hücrelere proses elemanı da denilir. Proses elemanları birbirine bağlandıkları gibi her bağlantının da kendine ait bir değeri mevcuttur. Şekil 2.1’de yapay sinir ağının yapısı görülmektedir.



Şekil 2.1 Bir yapay sinir ağı örneği

Bir yapay sinir ağıının başlıca görevi, kendisine tanıtılan bir girdi setine karşılık bir çıktı seti oluşturmaktır. Bunu yapabilmesi için ağ ilgili problemin değerleri ile eğitilerek öğrenme yapabilecek yeteneğe sahip hale getirilir.

2.3 Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının özellikleri, kullanılan modele göre değişiklik göstermektedir. Burada bütün modeller için gerekli olan genel özelliklere değinilmiştir. Günümüzde bir çok bilim alanında yapay sinir ağları aşağıdaki özellikleri nedeniyle etkin olmuş ve uygulama yeri bulmuştur.

2.3.1 Doğrusal Olmama

Yapay sinir ağlarındaki proses elemanları doğrusal olmadığı için yapay sinir ağları da doğrusal değildir. Bu özellik, yapay sinir ağları ile doğrusal olmayan karmaşık problemlerin çözümüne imkan sağlamaktadır.

2.3.2 Öğrenme

Yapay sinir ağlarında istenilen, ağa gösterilen girdi setine karşılık uygun çıktı setini üretmesidir. Bunun için hücreler arasında doğru bağlantıların uygun ağırlıklara sahip olması gerekir. Yapay sinir ağlarının karmaşık yapısı sebebiyle gerçek ağırlıklar önceden belirlenemez. Bu sebeple yapay sinir ağları kendisine tanıtılan problemin örneklerini kullanarak öğrenme işini gerçekleştirir.

2.3.3 Uyarlanabilirlik

Yapay sinir ağları ilgilendiği problemdeki değişiklikleri dikkate alarak proses elemanları arasındaki ağırlık değerlerini değiştirebilmektedir. Yani uygulama için oluşturulan yapay sinir ağı modeli uygulamalarda yer alan değişiklikler için tekrar eğitilebilir.

2.3.4 Hata Toleransı

Yapay sinir ağları, çok fazla proses elemanının çeşitli şekillerde bağlantılarıyla oluşmuştur. Eğitimli tamamlanmış bir yapay sinir ağının bazı bağlantılarının ve hücrelerinin eksik olması halinde ağ çalışmaya devam eder. Bu sebeple yapay sinir ağlarının hatayı tolere etme yetenekleri oldukça yüksektir.


2.4 Biyolojik Sinir Hücresi

Biyolojik sinir ağı insan beynindeki çok sayıda sinir hücresinin bir araya gelerek oluşturduğu kompleks bir yapıdır. Bir sinir ağı milyonlarca sinir hücresinin bir araya gelmesiyle oluşmaktadır. Merkezi sinir sisteminin temel işlem elemanı sinir

hücresidir. İnsan beyinde yaklaşık 10 milyar sinir hücresi (nöron) olduğu tahmin edilmektedir.

Biyolojik sinir ağları duyulardan gelen bilgiler ışığında algılama ve anlama mekanizmalarını uyarak olaylar arasındaki ilişkileri öğrenme yeteneğine sahiptir (Öztemel 2003). Günümüzde bilim adamları beynin yaptığı bu işlemleri yapabilecek bilgisayarlar yapmak için yapay zeka konusunda çalışmaktadır. İşte bilgisayar teknolojisinde ulaşılmak istenen nokta insan beyninin gerçekleştirdiği fonksiyonları ve işlevleri yerine getirilebilen bir yazılım ortaya koymaktır. Bunun başlıca nedeni insan beyninin düşünme, var olan bilgi ve tecrübelerden sonuç çıkarma, zarar verme gibi işlemleri yerine getirilebilmesi ve bunları kısa bir sürede gerçekleştirme becerisidir.

Yapay sinir ağlarındaki işleme elemanları biyolojik olarak insan beyindeki nöronlarla benzer yapıdadır. Bir sinir hücresi Şekil 2.2’de şematik olarak görülmektedir. Dendrit olarak adlandırılan yapı, diğer hücrelerden bilgiyi alan nöron girişleri olarak görev yapar. Diğer hücrelerde bilgiyi transfer eden eleman aksonlardır. Aksonlar nöron çıkışları olarak görev yapmaktadır. Snaps ise akson ve dendrit arasındaki bağlantıyı sağlar.




Şekil 2.2 Biyolojik sinir hücresinin yapısı (Öztemel 2003)

Milyonlarca sinir hücresi bir araya gelerek insanın sinir sistemini oluşturmaktadır. Yapay sinir ağlarının işleyişi de biyolojik sinir ağına benzer olarak gelişmektedir. Buradan biyolojik sinir ağlarının yapay sinir ağlarına modellik ettiği anlaşılmaktadır.

2.5 Yapay Sinir Hücresi

Yapay sinir hücresi (proses elemanı), yapay sinir ağının çalışmasına esas teşkil eden en küçük bilgi işleme birimidir. Geliştirilen modellerde bazı farklılıklar olmakla birlikte genel özellikleri ile bir proses elemanı Şekil 2.3’de görüldüğü gibi girişler, ağırlıklar, toplama fonksiyonu, aktivasyon (etkinleştirme) fonksiyonu ve çıktılar olmak üzere beş bileşenden meydana gelir.



Şekil 2.3 Yapay sinir hücresi (Öztemel 2003)

1. Girişler

Girişler, diğer hücrelerden veya dış ortamdan hücreye giren bilgilerdir.

2. Ağırlıklar

Ağırlıklar, ilgili girişlerin hücre üzerindeki etkisini belirleyen katsayılardır. Her giriş için bir ağırlık değeri mevcuttur.





3. Toplama Fonksiyonu


Toplama fonksiyonu bir hücreye gelen net girdiyi hesaplayan bir fonksiyondur. Değişik fonksiyon türleri olmakla birlikte genellikle net girdi, girişlerin ilgili ağırlıkla çarpımlarının toplamıdır. Toplama fonksiyonu olarak değişik formüllerin kullanıldığı görülmektedir. Bazı durumlarda gelen girdilerin değeri dikkate

alınırken bazı durumlarda ise gelen girdilerin sayısı önemli olabilmektedir. Bir problem için en uygun toplama fonksiyonunu belirlemek için bulunmuş bir formül yoktur. Genellikle deneme yanılma yolu ile toplama fonksiyonu belirlenmektedir (Öztemel 2003).

4. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, toplama fonksiyonundan elde edilen net girdiyi bir işlemden geçirerek çıktıyı belirler. Çıktı hesabı için değişik aktivasyon fonksiyonları kullanılmaktadır. En sık kullanılan aktivasyon fonksiyonu sigmoid fonksiyonudur. Aktivasyon fonksiyonu Şekil 2.4’de gösterilen grafiklerin birisi şeklinde olabilmektedir.






Şekil 2.4 En çok kullanılan aktivasyon fonksiyonları (Elmas 2003)

5. Hücre Çıktısı

Aktivasyon fonksiyonunun, dış ortama veya diğer hücelere aktarım yapılan yerdir. Hücre birden fazla girdi değeri için de tek çıktı üretmektedir.

2.6 Yapay Sinir Ağının Yapısı

Yapay sinir ağları, hücrelerin birbirleri ile çeşitli şekillerde bağlanmalarından oluşur. Yapay sinir ağlarında değerlerin girildiği giriş katmanı, ağın ürettiği çıktılar için çıkış katmanı ve giriş ve çıkış katmanları arasındaki ara katman olmak üzere üç farklı katman mevcuttur. Şekil 2.5’de üç katmana sahip yapay bir sinir ağı şematik olarak gösterilmektedir.



Şekil 2.5 Üç katmanlı bir yapay sinir ağı

Yapay sinir ağlarında her katmana ait proses elemanları birbirleriyle bağlantılıdır. Bu bağlantılar ağırlık değerini oluşturur. Ağa gelen bilgiler önce giriş katmanındaki proses elemanları ve bağlantılarla ara katmanın proses elemanlarına sonra aynı şekilde çıkış katmanına ulaşır. Çıkış katmanındaki proses elemanları

kendisine gelen bilgileri toplayarak çıkış değerini belirler. Bir ağda giriş katmanından çıkış katmanına doğru ara katmanlar üzerinden tek yönlü bir ilerleme mevcuttur.

Yapay sinir ağlarında beklenen sonucun elde edilebilmesi için uygun ağırlıkların seçilmesi gerekir. Ağ bu koşulları sağlayabilmek için öğrenme yeteneğine sahip olması gerekir. Öğrenme; giriş değerlerine veya bu girişlerin çıkışlarına bağlı olarak ağın bağlantı ağırlıklarını değiştiren veya ayarlayan öğrenme kuralı ile gerçekleştirilir (Elmas 2003). Genel olarak bütün yapay sinir ağlarının sahip olduğu topolojik bir yapı söz konusudur. Giriş ve çıkış katmanındaki proses elemanlarının sayıları problemin şartlarına göre belirlenir. Buna karşılık ara katman ve ara katmandaki proses elemanı sayısı için geliştirilmiş bir kural yoktur. Ara katman ve ara katmana ait proses elemanı sayısı sadece deneme yanılma yoluyla belirlenebilir.

Yapay sinir ağlarının genel olarak işleyiş prensibi girdi setine karşılık uygun çıktı seti üretmektir. Ağın bunu yapabilmesi için eğitilmesi gereklidir. Yapay sinir ağı, nümerik değerlerle çalıştığı için nümerik olmayan girişlerin nümerik hale getirilmesi gerekmektedir.


2.7 Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarında öğrenme, ağdan çıktılara karşılık gelen ağırlık değerlerinin belirlenmesi işlemidir. 1950’li yıllardan bugüne kadar birçok araştırmacı yapay sinir ağlarında öğrenmeyi geliştirecek çalışma içine girmiştir. Geliştirilen öğrenme metotları iki grupta toplanmıştır.

2.7.1 Danışmanlı Öğrenme

Danışmanlı öğrenme yönteminde giriş ve çıkış değerleri birlikte ağa sunulur. Yapay sinir ağının işlevi giriş değerlerini danışmanın belirlediği çıkış değerlerine uyarlamaktadır. Yapay sinir ağlarında ağın ürettiği çıkış değerleri bulunan çıkış değerleriyle mukayese edilir. Başlangıçta rasgele atanan ağırlıklar döngünün ilerleyen aşamalarında değiştirilerek hata oranı azaltılır. Hata kabul edilebilir seviyeye gelinceye kadar ağ eğitime devam etmekte ve ağırlıklar değiştirilmektedir. Ağ öğrenmeyi tamamladığında ağırlıklar değiştirilmez. Ağın öğrenme işini gerçekleştirmesi ilgili olayın giriş ve çıkış değerleri arasındaki ilişkiyi kavraması demektir. Böylece ağa sunulan farklı örnek setleri için doğru

sonular elde edilmektedir. Danışmanlı öğrenmeye ok katmanlı algılayıcılar rnek verilebilir. Şekil 2.6’da danışmanlı öğrenme grlmektedir.




Şekil 2.6 Danışmanlı öğrenme (Elmas 2003)

2.7.2 Danışmansız Öğrenme

Danışmansız öğrenme metodunda yapay sinir ağına yardımcı olan danışman yoktur. Bu yöntemde sisteme sadece giriş deęerleri sunulur. Ağ giriş deęerlerine karşılık gelecek ıktı setini oluşturunak parametreleri belirleyerek öğrenmeyi gerekleştirmektedir.

Danışmansız olarak eğitilebilen yapay sinir ağıları giriş setindeki deęerlerin zelliklerine göre ağırlık deęerlerini belirler. Sınıflandırma problemlerinin özümünde yaygın olarak kullanılmaktadır. Danışmansız öğrenmeye ART ağıları rnek olarak gösterilebilir. Grossberg tarafından geliştirilen danışmansız öğrenme yönteminin kullanıldığı ART ağıları biyolojik sinir ağılarının alışmasından esinlenmiştir. Danışmansız öğrenme Şekil 2.7 ’de yer almaktadır.



Şekil 2.7 Danışmansız öğrenme (Elmas 2003)

Danışmansız öğrenmede ara katman dışarıdan destek almadan kendilerini geliştirmek durumundadır. Ağa çıktı seti sunulmadığı için önceden bilinmeyen değerlerin belirlenmesi ağın kendisini denetleyerek yaptığı denemelerle gerçekleşmektedir. Danışmansız öğrenme, yapay sinir ağlarının gelecekte daha da gelişmesine öncülük edebilecek bir yöntemdir.

2.7.3 Bilinen Öğrenme Kuralları

Yapay sinir ağlarında değişik öğrenme kuralları bulunmaktadır. Öğrenme kurallarının bir çoğu Hebb öğrenme kuralı olarak bilinen basit bir modele dayanmaktadır. Bilinen öğrenme kurallarından bazıları aşağıda verilmiştir.

2.7.3.1 Hebb Kuralı

Geliştirilen ilk öğrenme kuralıdır. Diğer öğrenme kurallarının gelişmesine öncülük etmiştir. Donald Hebb tarafından geliştirilen öğrenme kuralının temeli, iki proses elemanı arasında bilgi alışverişi varsa ve iki proses elemanı da aktifse arasındaki bağ kuvvetlenmeli esasına dayanmaktadır. Yani aktif olan proses elemanı bağlantılı olduğu proses elemanını da aktif hale getirmeye çalışacaktır.

2.7.3.2 Hopfield Kuralı

Hebb kuralıyla benzerlik göstermektedir. Bu kurala göre beklenen giriş ve çıkış değerlerinin ikisinin birden aktif olması durumunda ağırlıklar öğrenme katsayısı kadar artırılır, pasif olması durumunda öğrenme katsayısı kadar azaltılır. Hopfield öğrenme kuralında ağırlıklar öğrenme katsayısı oranında değişmektedir.

2.7.3.3 Delta Kuralı

En sık kullanılan öğrenme kuralıdır. Bu kural en küçük ortalamalar karesi kuralı olarak da isimlendirilir. Bu kurala göre ağın ürettiği çıkış değerleri ile gerçek çıkış


değerleri arasındaki farkı azaltmak için bağlantıların ağırlık değerlerinin değiştirilmesi gerekmektedir. Başlangıçta ağırlık değerleri rasgele atanır. Ağırlıkların değişimi hatanın kabul edilebilir seviyeye inmesiyle son bulur. Delta öğrenme kuralının amacı, ağın ürettiği çıktı ile gerçek çıktı arasındaki farkın karelerinin ortalamasını en düşük seviyeye çekmektedir.

2.7.3.4 Kohonen Kuralı

Kohonen tarafından geliştirilen bir öğrenme kuralıdır. Bu kurala göre ağın bütün proses elemanları ağırlık değerlerini değiştirmek için yarış içersindedirler. En büyük çıkışa sahip sinir yarışmayı kazanmakta ve ağırlıkları düzenleyebilmektedir. Ayrıca komşu hücrelerin ağırlık değerlerinin değişimine izin verilmektedir.

2.8 Tek Katmanlı Algılayıcılar (TKA)

Ara katmanı bulunmayan sadece giriş ve çıkış katmanından oluşan yapay sinir ağı tek katmanlıdır. Giriş ve çıkış katmanındaki proses elemanları birbiriyle bağlantılı durumdadır. Bu tür ağlarda sonucu sıfırdan farklı kılmak için eşik değeri (ϕ) mevcuttur (Öztemel 2003). Basit bir tek katmanlı algılayıcının yapısı Şekil 2.8’ de görülmektedir.



Şekil 2.8 Tek katmanlı algılayıcı modeli (Öztemel 2003)

Ağırlıkların giriş değerleri ile çarpımına eşik değerinin de eklenmesiyle çıkış değeri elde edilir. Çıkış değeri;

$$\zeta = \sum_{i=1}^n w_i x_i + \emptyset \quad (2.1)$$

ile hesaplanır. Burada; w_i : Ağırlık değeri, x_i : Giriş değeri, $\emptyset$: Eşik değeridir.

$$f(x) = \begin{cases} 1 & \zeta > 0 \\ -1 & \zeta < 0 \end{cases} \quad (2.2)$$

Yukarıdaki formülde toplam girdinin pozitif olması durumunda çıkışın pozitif olup 1 değerini alacağı, toplam girdinin negatif olması durumunda çıkışın negatif olup -1 değerini alacağı söylenebilir.

2.8.1 Perceptron

İlk defa 1958 yılında Rosanblatt tarafından sınıflandırma amacı ile geliştirilmiştir (Öztemel 2003). Perceptron en eski sinir ağlarından birisidir. Ağın üretmiş olduğu çıktı değerleri 1 veya sıfırdır. Perceptron birden fazla giriş değeri için de ancak bir çıktı üreten modeldir.

Perceptron ağırlık değerlerinin değişimine imkan sağlaması sebebiyle eğitilebilen bir ağıdır. Ağın ürettiği çıktı değeri ağdan beklenen değerden farklıysa eşik değeri ve ağırlıklar değiştirilir. Perceptron modelinde toplam girdi, eşik değeri $\emptyset$ ile karşılaştırılır. Ağın çıkış değeri, toplam girdinin eşik değeri olan $\emptyset$ 'den büyük olması durumunda 1, küçük olması durumunda sıfırdır.

Perceptron modelinde ağın toplam girdisi aşağıdaki gibi hesaplanır.

$$NET = \sum_{i=1}^n w_i x_i \quad (2.3)$$

Perceptron modelinin çıktısı hesap edilir. Çıkış değerinin eşik değerinden büyük yada küçük olmasına göre ağın çıktısı belirlenir.

$$\zeta = \begin{cases} 1 & \text{eğer } NET > \emptyset \\ 0 & \text{eğer } NET < \emptyset \end{cases} \quad (2.4)$$

2.8.2 ADALINE Modeli

ADALINE bir sinir hücresinden oluşan basit bir ağ modelidir. Günümüzde yaygın kullanım alanı olan ADALINE ağının öğrenme kuralı delta öğrenme kuralı şeklinde de adlandırılır. Yapı olarak tek katmanlı algılayıcıya benzemektedir.

ADALINE modeli öğrenmeyi en küçük kareler yöntemiyle gerçekleştirmektedir. Perceptron modeline benzerlik göstermektedir. ADALINE modelinde toplam girdi şu şekilde hesaplanmaktadır.

$$NET = \sum_{i=1}^n w_i x_i + \emptyset \quad (2.5)$$

ADALINE modelinin çıktısı hesap edilir. Toplam girdinin sıfırdan büyük olup olmamasına bağlı olarak ağın çıktısı belirlenir.

$$\zeta = \begin{cases} 1 & \text{eğer } NET > 0 \\ -1 & \text{eğer } NET < 0 \end{cases} \quad (2.6)$$

ADALINE modelinde eğitim sırasında giriş değerlerine karşılık ağın ürettiği çıkış seti oluşturulur. Ağın ürettiği çıkış ile gerçek çıkış arasındaki fark hata olarak kabul edilir. ADALINE modelinin öğrenme kuralı olan delta öğrenme kuralı, hatanın en aza inmesi için ağırlıklarının değiştirilmesi esasına dayanır. ADALINE modelinde ağın hatası şu şekilde hesaplanır.

$$E = G - \zeta \quad (2.7)$$

Burada, E: Ağın hatası, G: Gerçek çıkış değeri, ζ : Ağın çıkış değeridir.

Maksat hatayı kabul edilebilir sınıra indirecek ağırlıkları elde etmektedir. Ağa sunulan her örnek için hatayı azaltacak şekilde ağırlıklar değiştirilir. Ağırlıkların değişimi i-nci düğüm için

$$w_i = w_{(i-1)} + E \alpha x_i \quad (2.8)$$

ifadesi elde edilir. Bu ifadede;

w_i : Ağırlığın yeni değeri , $w_{(i-1)}$: Ağırlığın değiştirilmeden önceki değeri,
 α : Öğrenme katsayısı, E : Ağıın hatası, x_i : Giriş değeridir.

Ağırlıkların değişmesine benzer biçimde eşik değerleri de değiştirilir. Değiştirilen eşik değerinin yeni değeri şu formüle göre bulunur.

$$\emptyset_s = \emptyset_i + \alpha E \quad (2.9)$$

Yukarıdaki formülde;


$\emptyset_s$: Yeni eşik değeri, $\emptyset_i$: Eşik değerinin değiştirilmeden önceki değeri,
 α : Öğrenme katsayısı, E : Ağıın hatasıdır.

Tek katmanlı algılayıcılar çok katmanlı algılayıcılara temel oluşturmuşlardır. Bu tür algılayıcılarda ağıın ürettiği çıkış değeri ile gerçek çıkış değeri arasındaki fark (hata), ağırlık ve eşik değerinin değiştirilmesiyle azaltılır. Ağırlık ve eşik değerinin her değişiminde hata miktarı da azalmaktadır. Tek katmanlı algılayıcıların en önemli özelliği sadece doğrusal problemleri öğrenip mantıklı sonuçlar üretmesidir.

2.9 Çok Katmanlı Algılayıcılar (ÇKA)

Tek katmanlı algılayıcılar sadece doğrusal problemleri öğrenebilmektedir. Tek katmanlı algılayıcılardan Perceptron modelinin geliştirilmesinden sonra yapay sinir ağlarının doğrusal olmayan olaylara çözüm üretmesinin mümkün olmadığı ortaya atılmıştır. Bu düşüncenin geçerliliği klasik XOR problemine dayanmaktadır. Doğrusal olmayan problemlere çözüm üretmek amacıyla yapılan çalışmalar çok katmanlı algılayıcıların bulunmasına sebep olmuştur.

Çok katmanlı algılayıcılar ileri yayımlı bir yapay sinir ağıdır. Çok katmanlı algılayıcı modelinde kullanılan öğrenme kuralı delta öğrenme kuralıdır. Delta öğrenme kuralı tek katmanlı algılayıcılardan ADALINE modelinin öğrenme kuralına benzerlik göstermektedir. Şekil 2.9 'da çok katmanlı algılayıcıların genel yapısı yer almaktadır.



Şekil 2.9 Çok katmanlı algılayıcı yapısı

Çok katmanlı algılayıcılarda giriş katmanı, ara katman ve çıkış katmanı olmak üzere üç ayrı katman mevcuttur. Ağda giriş ve çıkış katmanları tek olmasına karşın ara katman sayısı değişiklik göstermektedir. Çok katmanlı algılayıcılar öğretmenli öğrenme stratejisini kullanır (Öztemel 2003). Öğretmenli öğrenme stratejisi, giriş değerleri ve bu değerlere karşılık gelen çıkış değerlerinin yapay sinir ağına birlikte sunulmasıdır.


Çok katmanlı algılayıcılarda giriş katmanına dış çevreden gelen bilgiler ağırlıklar üzerinden ara katmana iletilir. Giriş katmanında değerlerde değişiklik olmaz. Ara katmana gelen bilgiler işlenerek bir sonraki katmana ve nihayet çıkış katmanına iletilir. Çıkış katmanına gelen bilgiler bu katmanda da işlenerek ağın çıkış değeri elde edilir.

Çok katmanlı algılayıcılarda ağın ürettiği çıkış değerleri ile gerçek çıkış değerleri arasındaki fark hata olarak kabul edilir. Oluşan hatayı azaltmak için ağın ağırlık değerleri değiştirilir. Hatanın ağ içerisinde hangi katman ve proses elemanında ne oranda mevcut olduğu bilinmediğinden toplam hatanın ağa dağıtılmasıyla sonuçlar değiştirilir. Ağırlıkların değiştirilmesi, çıkış katmanına bağlı ağırlıklardan başlayarak giriş katmanına bağlı ağırlıkların değiştirilmesiyle son

bulur. Sonuçta işlemler ters yönde devam eder. Çok katmanlı algılayıcı modelinde ağın yaptığı hatayı öğrenip beklenen sonucu bulana kadar işlemler devam eder.


2.9.1 Ağın Eğitimi

Yapay sinir ağlarında uygun olan ağırlık değerlerinin bulunmasına ağın eğitilmesi denilir. Çok katmanlı algılayıcı modelinde de eğitim işlemi değişmemektedir. Başlangıçta gerekli olan ağırlık değerleri bilinmemektedir. Bu nedenle ağın başlangıç ağırlık değerleri keyfi olarak atanmaktadır. Ağın ürettiği hatayı en aza indirmek için ağırlıklar değiştirilerek eğitime devam edilmektedir. Şekil 2.10'da öğrenmenin hata uzayındaki gösterimi görülmektedir.



Şekil 2.10 Öğrenmenin hata uzayındaki gösterimi (Öztemel 2003)


Şekilde w^* en az hataya karşılık gelen ağırlık değerini göstermektedir. Ağın sahip olması gereken ağırlık değeri de w^* 'dur. Bu çözüm ağın ulaşabileceği en uygun sonucu veren optimum çözümdür. Bu çözüme ulaşmak her zaman mümkün olmayabilir. Çünkü probleme ait hata uzayı yukarıdaki şekilde olduğu gibi devamlı iki boyutlu olmayabilir. Hata uzayının kompleks bir yapısı Şekil 2.11'de görülmektedir.



Şekil 2.11 Çok katmanlı algılayıcılarda genel hata uzayı (Öztemel 2003)

Yapay sinir ağlarının tümü eğitimini belli oranlarda hata ile tamamlar. Ağdan beklenen hatayı en aza indireyecek olan ağırlık değerlerine sahip olmasıdır. Bu yüzden yapay sinir ağlarında hatanın kabul edilebilir bir sınır düzeyi (tolerans değeri) olduğu kabul edilmektedir. Tolerans değerinin altında kalan her bölgede ağırlık öğrenimini tamamladığı, üzerinde kalan bölgelerde ise öğrenimini tamamlamadığı kabul edilir. Tolerans değerinin üzerindeki bölgeler yerel çözüme ait sonuçlardır. Şekil 2.11’de W_1 değerine sahip çözüm tolerans değerinin üzerinde olduğu için yerel çözüme, W_2 değerine sahip çözüm tolerans değerinin altında kaldığı için uygun çözüme sahiptir. Yapay sinir ağlarından elde edilen çözümlerin hangisinin yerel çözüm, hangisinin uygun çözüm olduğu bilinmemektedir.

Yapay sinir ağlarında eğitim sırasında iyi bir yerel çözüm elde edilebilir. Bu çözüm ağırlık üretebileceği uygun çözümdür demek yanlış olur. Çok katmanlı algılayıcılarda yerel çözümleri uygun çözümlere yaklaştırmak için momentum katsayıları geliştirilmiştir. Hatanın iterasyon sayısına bağlı durumu Şekil 2.12’de görülmektedir.



Şekil 2.12 Çok katmanlı algılayıcılarda hatanın iterasyon sayısına bağlı değişimi

Yapay sinir ağlarında iterasyon sayısının artması hatanın azalmasını sağlayacaktır. Yapay sinir ağlarında; ağın topolojisi, giriş ve çıkış değerleri, ara katman sayısı gibi etkenler uygulanacak olan iterasyon sayısını değiştirmektedir. Şekil 2.12 incelenirse hatanın belirli bir iterasyon sayısından sonra azalmadığı sonucuna varabiliriz.

2.9.2 Genelleştirilmiş Delta Kuralı

Genelleştirilmiş delta kuralı iki adımdan oluşmaktadır. İlk adımda ağın ürettiği çıktı hesaplanır. İkinci adımda ağın ürettiği hatayı en aza indirecek yeni ağırlıklar oluşturulur (Öztemel 2003). Giriş katmanına ait proses elemanlarının sahip oldukları ağırlıklarla çarpımı ara katmandaki proses elemanının net girdisini oluşturur. Ara katmana ait proses elemanının net girdisi aşağıdaki gibi hesaplanır.

$$NET = \sum_{k=1}^n A_{KJ} G_k \quad (2.10)$$

Bu ifadede;

A_{kj} : k. giriş katmanı proses elemanı ile j. ara katman proses elemanı arasındaki ağırlık değeri, G_K : Giriş katmanındaki k. proses elemanının çıkış değeridir.

Ara katmana ait proses elemanının çıktısı hesaplanan net girdinin aktivasyon fonksiyonunda işlenmesiyle elde edilir (Öztemel 2003). Değişik aktivasyon

fonksiyonları olmakla birlikte en çok kullanılanı sigmoid fonksiyonudur. Aktivasyon fonksiyonu olarak sigmoid fonksiyonunun kullanılması durumunda çıktı aşağıdaki gibi hesaplanır.

$$\zeta = \frac{1}{1 + e^{-(NET)}} \quad (2.11)$$

Ara katman ve çıkış katmanına ait proses elemanlarının çıktıları benzer şekilde hesaplanır. Ara katman ve çıkış katmanındaki her proses elemanının hesaplanan net girdisi sigmoid fonksiyonunda işlenerek çıktılar hesaplanır.

Ağın ürettiği çıkış değeri ile gerçek çıkış değeri arasındaki fark hata olarak kabul edilmektedir. Genelleştirilmiş delta kuralı , hatanın ağırlık değerine dağıtılmasıyla oluşturulan yeni ağırlıklar sayesinde hatayı kabul edilebilir seviyeye indirmektedir. Çıkış katmanına ait bir proses elemanının hatası aşağıdaki gibi hesaplanır.

$$E = G - \zeta \quad (2.12)$$

Bu ifadede; E: Bir proses elemanının hatası, G: Gerçek çıkış değeri, ζ : Ağın çıkış değeridir.

Tek proses elemanı için oluşan hata yukarıda verilmiştir. Ağın toplam hatası ise aşağıdaki gibi hesaplanır.

$$TH = \frac{1}{2} \sum E^2 \quad (2.13)$$

Toplam hatanın azalması için çıkış katmanı ile ara katman arasındaki ağırlıklar, ara katmanlar arasındaki ağırlıklar ve ara katman ile giriş katmanı arasındaki ağırlıkların değiştirilmesi gerekmektedir (Öztemel 2003). Katmanlar arasındaki ağırlıkların değiştirilmesi benzerlik gösterdiği için burada ara katman ile çıkış katmanı arasındaki ağırlıkların değişimi anlatılacaktır. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılması halinde çıkış katmanına ait i. çıkış elemanının hatası aşağıdaki gibi hesaplanır.

$$\delta_i = \zeta_i (1 - \zeta_i) E_i \quad (2.14)$$

Bu ifadede; δ_i : i. çıkış ünitesinin hatası, ζ_i : Çıkış değeri, E_i : Hatadır.

Öncelikle ağırlıkların değişim miktarının hesap edilmesi gerekmektedir. Ara katman ile çıkış katmanı arasındaki ağırlıkların t. iterasyonda değişim miktarı aşağıdaki gibi hesap edilir.

$$\Delta A_{ji}(t) = \lambda \delta_i C_j + \alpha \Delta A_{ji}(t-1) \quad (2.15)$$

Yukarıdaki ifadede; λ : Öğrenme katsayısı, α : Momentum katsayısı, ΔA_{ji} : Ara katmandaki j. proses elemanı ile çıkış katmanındaki i. proses elemanı arasındaki ağırlığın değişim miktarıdır.

Ara katman ile çıkış katmanı arasındaki yeni ağırlıkların t. iterasyona ait değerleri aşağıdaki gibi hesaplanır.

$$A_{ji}(t) = A_{ji}(t-1) + \Delta A_{ji}(t) \quad (2.16)$$

Bu ifadede; A_{ji} : Ağırlığın yeni değeri, ΔA_{ji} : Ağırlığın değişim miktarıdır.

Genelleştirilmiş delta kuralında ağın ürettiği çıkış değerleriyle gerçek çıkış değerleri arasındaki fark kabul edilebilir seviyeye gelinceye kadar ağırlıklar sürekli değişmektedir.

2.9.3 Öğrenme ve Momentum Katsayıları

Yapay sinir ağırlığında ağa sunulan örnek seti kadar öğrenme ve momentum katsayılarının belirlenmesi de ağın performansı üzerinde önemli bir etkiye sahiptir. Öğrenme katsayısı ağırlıkların değişim oranını yansıtan bir katsayıdır. Öğrenme katsayısının küçük değerleri için ağın eğitimi uzamaktadır. Büyük değerleri için ağ eğitimi hızla tamamlamaktadır. Fakat büyük değerlerin kullanılması durumunda ağın her zaman uygun çözüme sahip olmadığı gözlenmektedir. Dolayısıyla öğrenme katsayısı olarak alınabilecek net bir değer yoktur. Öğrenme katsayısı olarak 0,2-0,8 arasındaki değerlerin alınması tavsiye edilmektedir.

Benzer tarzda momentum katsayısının da yapay sinir ağının performansına etkisi sözkonusudur. Momentum katsayısının büyük değerleri için ağdaki toplam hata azalış göstermektedir. Momentum katsayısı olarak 0,6-0,8 arasındaki değerlerin alınması tavsiye edilmektedir.

2.9.4 Ara katman ve Proses Elemanlarının Sayısı

Yapay sinir ağlarında belirsizlik içeren kavramlardan biri de ara katman ve ara katmandaki proses elemanı sayısıdır. Bu durum ağın performansını etkilemektedir. Ara katman sayısının düşük alınması ağın hata miktarını olumsuz yönde etkilemektedir. Ara katmanın artırılması her yapay sinir ağında uygun çözümü sağlamaz. Ara katman ve ara katmana ait proses elemanı sayısı için geliştirilmiş bir yöntem yoktur. Bu konuda sadece deneme yanılma yönteminden yararlanılır. Mühendislik problemlerinin bir çoğunda bir ara katman sayısının yeterli olduğu önerilmektedir.

2.10 İleri ve Geri Beslemeli Yapay Sinir Ağları

Bütün yapay sinir ağları genel olarak giriş katmanı, ara katman ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır. İleri beslemeli ağlarda giriş katmanına ait bir proses elemanının çıkış değeri bağlantılı olduğu ara katmana ait proses elemanının giriş değeridir. Benzer şekilde ara katmana ait bir proses elemanının çıkış değeri bağlantılı olduğu ara katman veya çıkış katmana ait proses elemanının giriş değeridir. Giriş katmanı dış çevreden gelen bilgileri değiştirmeden ara katmana iletir. Bilgiler ara katman ve çıkış katmanda işlenerek ağın çıkış değerleri belirlenir. Ağın bu yapısı doğrusal olmayan problemlere çözüm üretilmesine imkan sağlar. Tek katmanlı algılayıcılardan perceptronun geliştirilmesinden sonra çok katmanlı ileri beslemeli ağlar üzerinde çalışılarak değişik modeller geliştirilmiştir. Geriye yayılım algoritması ileri beslemeli ağlarda rahatça kullanılmaktadır.


Geri beslemeli ağlarda adından da anlaşılacağı gibi geri besleme işlemi mevcuttur. Geri beslemeli yapay sinir ağlarında herhangi bir proses elemanının çıkış değeri kendisine veya diğer bir proses elemanına giriş olarak aktarılır. Geri besleme, bir katmanın proses elemanları arasında yapıldığı gibi katmanlar arasındaki proses elemanları arasında da yapılabilir.

Genellikle geri beslemeli yapay sinir ağları ölçülemeyen girişleri olan dinamik sistemlerin modellenmesinde kullanılarak başarı kaydetmiştir.

2.11 Hopfield Ağı

1980'lerin başında John Hopfield tarafından geliştirilen bir modeldir. Hopfield ağı tek katmanlı ve geri dönüşümlü bir ağıdır (Öztemel 2003). Hopfield ağının yapısı

diğer ağlardan farklılık gösterir. Hopfield ağının her proses elemanı diğerleriyle bağlantılı olup bağlantılar çift yönlüdür. Hopfield ağının basit yapısı Şekil 2.13’de görülmektedir.



Şekil 2.13 Hopfield ağı örneği (Elmas 2003)


Hopfield ağı belirli hafıza veya desenleri depolayan basit bir sinir ağıdır. Ağdaki bağlantılar kararlılık gösterir. Bu durum ağdaki bazı proses elemanı ve bağlantıların yetersiz olması halinde ağı işleyişinin bozulmamasını sağlar. Hopfield ağı bir proses elemanının büyük sinir ağlarının davranış analizlerine nasıl izin verdiğini açıklamaktadır.

Hopfield ağında her proses elemanının +1 veya -1’den oluşan değeri vardır. Hücrenin sahip olduğu bu değerlere giriş desenleri de denilmektedir. Hopfield ağlarında desenler giriş olarak ağı iletilir. Ağ içerisindeki proses elemanları birbirleriyle etkileşime girerler. Etkileşim hücreler arasındaki bağlantıların ağırlıkları tarafından gerçekleşir.

2.12 LVQ (Linear Vektor Quantization) Ağı

LVQ ağı Kohonen tarafından 1984 yılında geliştirilmiştir (Öztemel 2003). Diğer yapay sinir ağlarında olduğu gibi LVQ ağına da giriş katmanı, ara katman ve çıkış katmanı olmak üzere üç katman bulunmaktadır. Giriş katmanı ile ara katman arasındaki bağlantı tamken ara katman ile çıkış katmanı arasındaki bağlantı kısmidir. Giriş katmanı ile ara katman arasındaki bağlantının ağırlık değeri değişmesine karşılık ara katman ile çıkış katmanı arasındaki bağlantının ağırlık

değeri daima 1'dir (Öztemel 2003). LVQ ağlarında çıkış değerleri 1 ve 0'dan oluşmaktadır. Çıkış değerinin 1 olması giriş işaretini sınıflandırır. LVQ ağının genel yapısı Şekil 2.14'de görülmektedir



Şekil 2.14 LVQ ağı (Öztemel 2003)

Şekilden de görüldüğü gibi üç katmandan oluşan LVQ ağlarında giriş katmanındaki her proses elemanı ara katmandaki bütün proses elemanı ile bağlantılıdır. Fakat ara katmandaki proses elemanları çıkış katmanındaki bir proses elemanı ile bağlantılıdır. Giriş katmanı ile ara katman arasındaki bağlantının ağırlık değerine referans vektörü denilmektedir.

LVQ ağlarında ara katman ve çıkış katmanındaki proses elemanları ikili (binary) çıkışa sahiptir. Ağa bir giriş deseni sunulduğunda referans vektörü giriş desenine en yakın olan ara katmanın proses elemanlarının çıktısı 1, diğerlerinin 0 olur. Yani ara katmanda hangi proses elemanının çıkış değeri 1 ise o proses elemanının bağlı bulunduğu çıkış katmanındaki proses elemanının çıkış değeri 1, diğer proses elemanlarının çıkış değeri 0 olur (Öztemel 2003). LVQ ağının yapısındaki bu

durum ağı performansının artmasını sağlamaktadır. LVQ ağı yaygın olarak sınıflandırma problemlerinde tercih edilen bir modeldir.

Giriş vektörüne yakınlaşan referans vektörünün belirlenmesi LVQ ağının eğitimi sırasında gerçekleşmektedir. Ara katman ile çıkış katmanı arasındaki bağlantının ağırlık değeri sabit olduğu için değiştirilmez. Referans vektörünün ağırlık değerleri değiştirilebilir. Giriş vektörü ile referans vektörünün en yakın olduğu ara katman proses elemanının çıkış değerinin 1 olduğu diğerlerinin 0 olduğu yukarıda ifade edilmektedir. Dolayısıyla ağın çıkış katmanına ait proses elemanlarından birinin çıkış değeri 1, diğerlerinin çıkış değeri 0 olmaktadır. LVQ ağının çıkış değeri doğrusa referans vektörü giriş vektörüne yaklaşır. Giriş setindeki bütün değerler sınıflanıncaya kadar işlem devam eder. Sınıflanmanın bitmesi ağın öğrenmeyi tamamladığı anlamına gelmektedir.

2.13 ART (Adaptif Rezonans Teori) Ağları

1970'lerde Stephen Grossberg tarafından geliştirilen danışmansız öğrenmeye dayalı ART ağları insan beyninin biyolojik yapısından esinlenerek geliştirilmiştir (Öztemel 2003). ART ağları sınıflandırma problemlerinin çözümünde yaygın olarak kullanılmaktadır.

ART ağının çalışma prensibi ağı sunulan girişlerin hafızada saklanarak uygun çıkışların üretilmesi esasına dayanmaktadır. Ağ değerlerin geçici olarak sakladığı kısa dönemli hafıza (KDH) ve devamlı olarak tutulduğu uzun dönemli hafızaya (UDH) sahiptir. Kısa dönemli hafızada (KDH) saklanan bilgiler yeni bilgilerin ağı sunulmasıyla silinir. Hangi bilginin kısa veya uzun dönemli olduğuna ağ kendisi karar verir. Danışmansız öğrenme yeteneğine sahip olan ART ağları uygun çıkış değerlerini dışarıdan destek almadan kendisi üretebilmektedir. Ağın bu özelliği hızlı öğrenme yeteneği ile ağın farklı olaylara karşı karar verebilmesine imkan sağlamaktadır.

Günümüzde çeşitli ART ağları bulunmaktadır. Genel olarak ART ağları giriş ve çıkış katmanı olmak üzere iki katmanlıdır. İki katman birbiriyle tam bağlantılı olup bağlantılar çift yönlüdür. ART ağlarında giriş katmanına gelen bilgiler çıkış katmanına iletilir. Sınıflandırmanın yapıldığı yer çıkış katmanıdır. ART ağlarında ileri yöndeki bağlantıların ağırlıkları toplamı ağın uzun dönemli hafızasını

oluřturur. Uzun d nemli hafıza giriř deęerlerinin benzerliklerini dikkate alarak  ıkıř proses elemanını oluřturur.

Benzer řekilde geri baęlantıların aęırlıkları toplamı aęın kısa d nemli hafızasını oluřturur. Hafızada saklanan deęerlerin giriř deęerleriyle  rt ř p  rt řmedięini kısa d nemli hafıza test eder. Yani giriř ve  ıkıř katmanından gelen deęerler eřleřtirilerek uygun bir sınıf oluřturulur.

3. MATERYAL VE METOD

Çalışmada yapay sinir ağının kafes kiriş üzerindeki etkinliğini araştırmak için beş farklı uygulama yer almaktadır. Uygulamalarda seçilen kafes kirişler izostatik ve düzlemseldir. Her uygulamada kafes kirişin sistem şekli, açıklığı ve yükleme durumu değiştirilmiştir. Düğüm noktaları mafsallı olarak düzenlenen kafes kirişlerin çubukları sadece eksenel yük etkisindedir. Dış yükler kafes kirişin düğüm noktalarına tekil olarak etkimektedir.

Uygulamalarda çok katmanlı ileri beslemeli geri yayımlı yapay sinir ağı modeli tercih edilerek hesaplamalar bu modele göre yapılmıştır. Yapay sinir ağının giriş değerleri olarak mesnet reaksiyonu dışındaki kirişe etkiyen dış yükler, çıkış değerleri olarak da kafes kirişin çubuk kuvvetleri alınmıştır.

Yapay sinir ağının problemi öğrenmesi için her uygulamada eğitme ve test işleminde kullanılmak üzere farklı yük kombinasyonu oluşturulmuştur. Her yük kombinasyonu için kirişin çubuk kuvvetleri analitik yöntemle hesaplanmıştır. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanıldığından eğitim setine ait çubuk kuvvetlerinin 0 -1 arasında olması için normalize işlemi yapılmıştır. Yapay sinir ağının eğitiminde dış yüklerden oluşan giriş değerleri ve normalize edilmiş çubuk kuvvetlerinden oluşan çıkış değerleri birlikte ağa sunulmuştur. Yapay sinir ağının eğitiminde her uygulama için 30.000 iterasyon yapılmıştır. Yapay sinir ağı hesabında öğrenme katsayısı 0,7, momentum katsayısı 0,9 alınmıştır. Yapay sinir ağı hesabında hazır bilgisayar programı kullanılmıştır. Eğitim işlemi sonunda elde edilen çıkış değerlerine normalize işleminin tersi uygulanarak yapay sinir ağının hesapladığı çubuk kuvveti değerleri elde edilmiştir.

Analitik yöntemle hesaplanan çubuk kuvvetleri ile yapay sinir ağıyla hesaplanan çubuk kuvvetlerinin farkı alınmıştır. Kiriş yükü, analitik yöntemle hesaplanan çubuk kuvvetleri, yapay sinir ağıyla hesaplanan çubuk kuvvetleri ve çubuk kuvvetleri arasındaki fark tablo haline getirilerek eğitim setleri oluşturulmuştur. Eğitim setlerinde yer alan farkların kareleri toplamının karekökü alınarak her eğitim setinin hatası hesaplanmıştır. Hesaplanan hata değerleri grafik olarak düzenlenmiştir. Uygulamanın eğitme işleminde ara katman sayısının belirlenmesine yönelik sabit ara katman düğüm sayısı ve sabit iterasyon (30.000)

sayısı altında ara katman sayısına bağılı oluşan hataların değeri belirlenmiştir. Oluşan hata değerleri grafik olarak düzenlenmiştir. Uygulamalarda tek ara katman kullanılmıştır.


Uygulamanın eğitime işlemi tamamlandıktan sonra yapay sinir ağının adaptif öğrenmesi için test işlemine geçilmiştir. Her uygulama için üç test seti oluşturulmuştur. Test seti eğitim setinde yer almayan giriş değerlerine sahiptir. Test işleminde yapay sinir ağına sadece giriş değerleri sunulmuştur. Test işlemi sonunda elde edilen çıkış değerleri kafes kirişin çubuk kuvvetini oluşturmaktadır. Eğitim setinde olduğu gibi giriş yükü, analitik yöntemle hesaplanan çubuk kuvvetleri, yapay sinir ağıyla hesaplanan çubuk kuvvetleri ve çubuk kuvvetleri arasındaki fark tablo haline getirilerek test setleri oluşturulmuştur.

4. İZOSTATİK KAFES SİSTEM ÇÖZÜMÜNDE YSA UYGULAMALARI

4.1Uygulama1

Düğüm noktalarının mafsallı olarak düzenlendiği taşıyıcı sistemlere kafes kiriş denilmektedir. Kafes kirişler mafsallı olarak düzenlendiği için çubuklar eğilmeye çalışmayıp sadece eksenel yük etkisinde bulunurlar. Yani kafes sistemin çubuklarında moment etkisi yoktur. Kafes kiriş içerisindeki çubuk birim uzamaya zorlanıyorsa çekme çubuğu, birim kısalmaya zorlanıyorsa basınç çubuğu olarak adlandırılır.


Kafes kirişlerde boyutlandırma çubuk kuvvetlerinin maksimum değerine göre yapılmaktadır. Kafes kirişlerde genellikle putrel kirişler kullanılır. Putrel kirişler homojen ve izotrop olması özellikleriyle hesap teorilerine oldukça iyi uyum sağlamaktadır. Kafes kirişin çözümü için geliştirilmiş değişik yöntemler bulunmaktadır. Çalışmanın bu aşamasında kafes kirişin çubuk kuvvetlerinin belirlenmesinde yapay sinir ağı kullanılacaktır. Uygulamada kullanılacak kafes kiriş Şekil 4.1’de yer almaktadır.



Şekil.4.1 Ölçü ve yükleme durumu verilen kafes kiriş

Uygulama için seçilen kafes kiriş izostatiktir. Alt ve üst başlık birbirine paralel olarak düzenlenmiştir. Kirişe etkiyen üç ayrı P_i kuvveti bulunmaktadır. Kirişin dokuz tane çubuğu mevcuttur. Yapay sinir ağının modellenmesi için giriş

değerleri olarak P_i kuvvetleri, çıkış değerleri olarak çubuk kuvvetleri alınmaktadır. Dolayısıyla yapay sinir ağı üç giriş ve dokuz çıkışa sahiptir. Bu problem için tek ara katman kullanılmıştır. Kafes kiriş problemi için oluşturulan yapay sinir ağı modeli Şekil 4.2’de yer almaktadır.



Şekil 4.2 Kafes kiriş probleminin yapay sinir ağı modeli

Yapay sinir ağının problemi öğrenmesi için kirişte değişik yük kombinasyonları oluşturulmuştur. Her yük kombinasyonuna ait kirişin çubuk kuvvetleri analitik yöntemle çözülmüştür. Burada analitik yöntemle bulunan çubuk kuvvetlerinin değerleri ile yapay sinir ağından elde edilen sonuçlar karşılaştırılacaktır.

Yapay sinir ağının eğitiminde 13 adet eğitim seti kullanılmıştır. Çok katmanlı algılayıcı modelinden yararlanılmıştır. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu tercih edildiği için çıkış değerleri 0-1 arasında normalize edilmesi gerekmektedir. Normalize işlemi için çubuk kuvvetleri 3,5 arttırılmış ve 6'ya bölünmüştür.

Normalize edilmiş çubuk kuvveti değerlerine göre hesaplanan yapay sinir ağı hesabında yaklaşık 30.000 iterasyon yapılmıştır. Yapay sinir ağıyla hesaplanarak bulunan çubuk kuvveti değerlerine normalize işleminin tersi uygulanır. Böylece yapay sinir ağının hesapladığı çubuk kuvvetleri belirlenmiş olup uygulamada 13 adet eğitim setine ait kiriş yükü, analitik yöntemle bulunan çubuk kuvvetleri ve yapay sinir ağıyla hesaplanan çubuk kuvveti değeri Tablo 4.1- 4.13’de yer almaktadır.

Tablo 4.1 Uygulama 1’in eğitim seti 1’e ait sayısal sonuçları

EĞİTİM SETİ 1				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-0,66	-0,662108	-0,002108
1	2	0	-0,00014	-0,00014
1	3	-1,5	-1,495544	0,004456
	4	0,83	0,827692	-0,002308
	5	-0,5	-0,500912	-0,000912
	6	-0,83	-0,83315	-0,00315
	7	-1	-1,006322	-0,006322
	8	0	-0,0002	-0,0002
	9	0,66	0,662518	0,002518

Tablo 4.2 Uygulama 1’in eğitim seti 2’ye ait sayısal sonuçları

EĞİTİM SETİ 2				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1,5	1	-0,66	-0,658724	0,001276
1	2	0	0,000154	0,000154
1	3	-2	-2,015264	-0,015264
	4	0,83	0,828184	-0,001816
	5	-0,5	-0,499262	0,000738
	6	-0,83	-0,828476	0,001524
	7	-1	-0,99275	0,00725
	8	0	0,000226	0,000226
	9	0,66	0,65668	-0,00332

Tablo 4.3 Uygulama 1'in eğitim seti 3'e ait sayısal sonuçları

EĞİTİM SETİ 3				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
2	1	-0,66	-0,660824	-0,000824
1	2	0	0,000136	0,000136
1	3	-2,5	-2,482364	0,017636
	4	0,83	0,830602	0,000602
	5	-0,5	-0,50069	-0,00069
	6	-0,83	-0,830294	-0,000294
	7	-1	-1,003688	-0,003688
	8	0	-8E-06	-8E-06
	9	0,66	0,658522	-0,001478

Tablo 4.4 Uygulama 1'in eğitim seti 4'e ait sayısal sonuçları

EĞİTİM SETİ 4				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
2,5	1	-0,66	-0,661166	-0,001166
1	2	0	-0,000182	-0,000182
1	3	-3	-3,014378	-0,014378
	4	0,83	0,82744	-0,00256
	5	-0,5	-0,50033	-0,00033
	6	-0,83	-0,832274	-0,002274
	7	-1	-1,001726	-0,001726
	8	0	-0,000158	-0,000158
	9	0,66	0,662332	0,002332

Tablo 4.5 Uygulama 1'in eğitim seti 5'e ait sayısal sonuçları

EĞİTİM SETİ 5				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
3	1	-0,66	-0,660464	-0,000464
1	2	0	6,4E-05	6,4E-05
1	3	-3,5	-3,46535	0,03465
	4	0,83	0,828424	-0,001576
	5	-0,5	-0,500252	-0,000252
	6	-0,83	-0,83048	-0,00048
	7	-1	-1,000328	-0,000328
	8	0	2,2E-05	2,2E-05
	9	0,66	0,658744	-0,001256

Tablo 4.6 Uygulama 1'in eğitim seti 6'ya ait sayısal sonuçları

EĞİTİM SETİ 6				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-1	-0,997526	0,002474
1,5	2	0	0,000328	0,000328
1	3	-1,75	-1,750088	-8,8E-05
	4	1,25	1,259548	0,009548
	5	-0,75	-0,748562	0,001438
	6	-1,25	-1,246106	0,003894
	7	-1	-0,995618	0,004382
	8	0	0,00043	0,00043
	9	1	0,999964	-3,6E-05

Tablo 4.7 Uygulama 1'in eğitim seti 7'ye ait sayısal sonuçları

EĞİTİM SETİ 7				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-1,33	-1,332782	-0,002782
2	2	0	-9,2E-05	-9,2E-05
1	3	-2	-1,999466	0,000534
	4	1,66	1,642918	-0,017082
	5	-1	-0,99989	0,00011
	6	-1,66	-1,666394	-0,006394
	7	-1	-1,007774	-0,007774
	8	0	-0,000344	-0,000344
	9	1,33	1,333294	0,003294

Tablo 4.8 Uygulama 1'in eğitim seti 8'e ait sayısal sonuçları

EĞİTİM SETİ 8				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-1,66	-1,6586	0,0014
2,5	2	0	0,00016	0,00016
1	3	-2,25	-2,251838	-0,001838
	4	2,083	2,10052	0,01752
	5	-1,25	-1,250036	-3,6E-05
	6	-2,083	-2,078978	0,004022
	7	-1	-0,995714	0,004286
	8	0	0,000292	0,000292
	9	1,66	1,655284	-0,004716

Tablo 4.9 Uygulama 1'in eğitim seti 9'a ait sayısal sonuçları

EĞİTİM SETİ 9				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2	-2,000138	-0,000138
3	2	0	0,000124	0,000124
1	3	-2,5	-2,499806	0,000194
	4	2,5	2,4619	-0,0381
	5	-1,5	-1,4993	0,0007
	6	-2,5	-2,501084	-0,001084
	7	-1	-1,001234	-0,001234
	8	0	6,4E-05	6,4E-05
	9	2	2,00179	0,00179

Tablo 4.10 Uygulama 1'in eğitim seti 10'a ait sayısal sonuçları

EĞİTİM SETİ 10				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-0,66	-0,660494	-0,000494
1	2	0	-0,000128	-0,000128
1,5	3	-1,5	-1,500086	-8,6E-05
	4	0,83	0,829672	-0,000328
	5	-0,5	-0,500594	-0,000594
	6	-0,83	-0,830324	-0,000324
	7	-1,5	-1,500254	-0,000254
	8	0	-9,8E-05	-9,8E-05
	9	0,66	0,659608	-0,000392

Tablo 4.11 Uygulama 1'in eğitim seti 11'e ait sayısal sonuçları

EĞİTİM SETİ 11				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-0,66	-0,659558	0,000442
1	2	0	0,000166	0,000166
2	3	-1,5	-1,500164	-0,000164
	4	0,83	0,830032	3,2E-05
	5	-0,5	-0,499208	0,000792
	6	-0,83	-0,829886	0,000114
	7	-2	-1,99988	0,00012
	8	0	0,000124	0,000124
	9	0,66	0,660328	0,000328


Tablo 4.12 Uygulama 1'in eğitim seti 12'ye ait sayısal sonuçları

EĞİTİM SETİ 12				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-0,66	-0,660002	-2E-06
1	2	0	1,6E-05	1,6E-05
2,5	3	-1,5	-1,50008	-8E-05
	4	0,83	0,829978	-2,2E-05
	5	-0,5	-0,499922	7,8E-05
	6	-0,83	-0,830042	-4,2E-05
	7	2,5	2,483392	-0,016608
	8	0	1,6E-05	1,6E-05
	9	0,66	0,660058	5,8E-05

Tablo 4.13 Uygulama 1'in eğitim seti 13'e ait sayısal sonuçları

EĞİTİM SETİ 13				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-0,66	-0,659996	4E-06
1	2	0	1E-05	1E-05
3	3	-1,5	-1,499966	3,4E-05
	4	0,83	0,829948	-5,2E-05
	5	-0,5	-0,49997	3E-05
	6	-0,83	-0,83	0
	7	-3	-2,999552	0,000448
	8	0	4E-06	4E-06
	9	0,66	0,660004	4E-06


Yapay sinir ağının eğitimi için oluşturulan eğitim setlerine ait sayısal sonuçlar Tablo 4.1'de yer almaktadır. Yapay sinir ağının kafes sistemi öğrenebilmesi için 13 eğitim seti oluşturulmuştur. Tablo incelendiğinde hata oranının kabul edilebilir sınır içerisinde kaldığı gözlenmektedir. Hata değerlerini ayrıntılı görebilmek için uygulamadaki eğitim setlerine ait ortalama hata değerleri Şekil 4.3'de yer almaktadır.



Şekil 4.3 Eğitim setlerine ait ortalama hata değerleri.


Grafik incelendiğinde en düşük hatanın 0,0005 değeri ile 13.eğitim setine ait olduğu, en yüksek hatanın ise 0,0382 değeri ile 9. eğitim setine ait olduğu görülmektedir. Eğitim setlerine ait ortalama hataların 0,0005 ile 0,0382 değerleri arasında değiştiği gözlenmektedir. Hata değerlerine bakarak yapay sinir ağının uygulama üzerindeki performansının iyi yönde olduğu anlaşılmaktadır.

Hatanın iterasyon sayısına bağlı değişimi Şekil 4.4’de yer almaktadır. Şekil 4.4’e bakıldığında 30.000’in üzerindeki iterasyonlarda oluşan hata değerinin azalışının ağın performansına katkısının önemli ölçüde olmadığı anlaşılmaktadır. Bu yüzden çalışmada 30.000 iterasyon yeterli görülmüştür.



Şekil 4.4 Hatanın iterasyon sayısına bağlı değişimi.

Yapay sinir ağlarında başlangıçta kesinlik içermeyen parametrelerden birisi de ara katman sayısıdır. Sabit ara katman düğüm sayısı (12) ve sabit iterasyon sayısı (30.000) altında ara katman sayısına bağlı hata oranı Şekil 4.5’de yer almaktadır. Grafik incelendiğinde ara katman sayısının artışı hata oranını azaltmaktadır. Bu uygulamada ara katman sayısını gereğinden fazla artırmak sonuçları önemli ölçüde değiştirmemektedir. Bu yüzden bu çalışmada tek ara katman yeterli görülmüştür.



Şekil 4.5 Sabit ara katman ve iterasyon sayısı altında ara katmana bağlı hata değişimi

Eğitme işleminden sonra yapay sinir ağının test edilmesi gerekmektedir. Test işlemi için üç test seti oluşturulmuştur. Test setinde yer alan giriş değerleri yapay sinir ağına sunularak ağdan uygun sonuçların elde edilmesi beklenmektedir. Test seti, eğitim setinde yer almayan değerlerden oluşmaktadır. Test setine ait sayısal sonuçlar Tablo 4.14 – 4.16’ da yer almaktadır.

Tablo 4.14 Uygulama 1’in test seti 1’e ait sayısal sonuçları

TEST SETİ 1				
Kiriş Yüğü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
0,5	1	-0,33	-0,369074	-0,039074
0,5	2	0	0,004756	0,004756
0,5	3	-0,75	-0,66857	0,08143
	4	0,415	0,381928	-0,033072
	5	-0,25	-0,296396	-0,046396
	6	-0,415	-0,470486	-0,055486
	7	-0,5	-0,858872	-0,358872
	8	0	-0,021158	-0,021158
	9	0,33	0,323446	-0,006554

Tablo 4.15 Uygulama 1'in test seti 2'ye ait sayısal sonuçları


TEST SETİ 2				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
2	1	-1,32	-1,260506	0,059494
2	2	0	-0,005204	-0,005204
2	3	-3	-2,43911	0,56089
	4	1,66	1,37092	-0,28908
	5	-1	-0,910094	0,089906
	6	-1,66	-1,491362	0,168638
	7	-2	-1,40825	0,59175
	8	0	-0,020486	-0,020486
	9	1,32	1,224046	-0,095954

Tablo 4.16 Uygulama 1'in test seti 3'e ait sayısal sonuçları

TEST SETİ 3				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-1,33	-1,53518	-0,20518
2	2	0	0,015664	0,015664
3	3	-2	-2,112104	-0,112104
	4	1,66	1,468738	-0,191262
	5	-1	-1,0361	-0,0361
	6	-1,66	-1,705418	-0,045418
	7	-3	2,391898	5,391898
	8	0	-0,047258	-0,047258
	9	1,33	1,423048	0,093048


4.2 Uygulama 2

Uygulama için üçgen kafes kiriş seçilmiştir. Kafes kiriş izostatik ve stabildir. Üçgen kafes kirişler çatılarda kullanılan bir sistem olarak karşımıza çıkmaktadır. Ölçü bakımından simetrik olan kafes kirişin düğüm noktası ve çubuk kuvveti sayısı ilk uygulamaya göre artırılmıştır. Kafes kirişe düşey olarak etkiyen 5 ayrı yük mevcuttur. Kafes kirişin 13 çubuğu bulunmaktadır. Uygulama için seçilen kafes kiriş Şekil 4.6’da yer almaktadır.



Şekil 4.6 Ölçü ve yükleme durumu verilen kafes kiriş

Kafes kirişlerin yapay sinir ağı ile modellenmesinde kirişe etkiyen dış yükler girişleri, kirişin çubuk kuvvetleri de çıkışları oluşturmaktadır. Bu uygulamada ağ 5 giriş ve 13 çıkışa sahiptir. Tek ara katman kullanılmıştır. Kafes kirişin çözümü için oluşturulan yapay sinir ağı modeli Şekil 4.7’de görülmektedir.



Şekil 4.7 Kafes kirişin yapay sinir ağı modeli

Yapay sinir ağının eğitme işleminde 13 eğitim seti bulunmaktadır. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. Normalize için çubuk kuvvetleri 7,8 artırılmış ve 16'ya bölünmüştür. Yapay sinir ağı hesabında yaklaşık 30.000 iterasyon yapılmıştır. Bu uygulamada 13 eğitim setine ait giriş yükü, analitik yöntemle bulunan çubuk kuvvetleri ve yapay sinir ağıyla hesaplanan çubuk kuvveti değerleri Tablo 4.17 -4.29'da yer almaktadır.

Tablo 4.17 Uygulama 2'nin eğitim seti 1'e ait sayısal sonuçları

EĞİTİM SETİ 1				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-3,9	-3,93976	0,03976
1	2	-2,6	-2,595872	-0,004128
1	3	-2,6	-2,593728	-0,006272
1	4	-3,9	-3,940464	0,040464
1	5	0	-0,000528	0,000528
	6	-1,3	-1,297264	-0,002736
	7	1	1,003856	-0,003856
	8	-1,3	-1,304752	0,004752
	9	0	0,005552	-0,005552
	10	3,6	3,5816	0,0184
	11	3,6	3,58832	0,01168
	12	3,6	3,589344	0,010656
	13	3,6	3,5904	0,0096

Tablo 4.18 Uygulama 2'nin eğitim seti 2'ye ait sayısal sonuçları

EĞİTİM SETİ 2				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1,5	1	-3,9	-3,88616	-0,01384
1	2	-2,6	-2,596016	-0,003984
1	3	-2,6	-2,599104	-0,000896
1	4	-3,9	-3,89472	-0,00528
1	5	0	-0,000848	0,000848
	6	-1,3	-1,30448	0,00448
	7	1	1,002704	-0,002704
	8	-1,3	-1,304704	0,004704
	9	0	-0,003632	0,003632
	10	3,6	3,605568	-0,005568
	11	3,6	3,604912	-0,004912
	12	3,6	3,60336	-0,00336
	13	3,6	3,605312	-0,005312

Tablo 4.19 Uygulama 2'nin eğitim seti 3'e ait sayısal sonuçları

EĞİTİM SETİ 3				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
2	1	-3,9	-3,910032	0,010032
1	2	-2,6	-2,601792	0,001792
1	3	-2,6	-2,599296	-0,000704
1	4	-3,9	-3,909664	0,009664
1	5	0	3,2E-05	-3,2E-05
	6	-1,3	-1,299072	-0,000928
	7	1	0,999744	0,000256
	8	-1,3	-1,2988	-0,0012
	9	0	0,003392	-0,003392
	10	3,6	3,596752	0,003248
	11	3,6	3,598768	0,001232
	12	3,6	3,599488	0,000512
	13	3,6	3,597312	0,002688

Tablo 4.20 Uygulama 2'nin eğitim seti 4'e ait sayısal sonuçları

EĞİTİM SETİ 4				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-4,875	-4,894336	0,019336
1,5	2	-2,925	-2,91792	-0,00708
1	3	-2,925	-2,920624	-0,004376
1	4	-4,225	-4,205232	-0,019768
1	5	0	0,003296	-0,003296
	6	-1,95	-1,934176	-0,015824
	7	1,25	1,249968	3,2E-05
	8	-1,3	-1,301184	0,001184
	9	0	0,00728	-0,00728
	10	4,5	4,499472	0,000528
	11	4,5	4,509312	-0,009312
	12	3,9	3,899952	4,8E-05
	13	3,9	3,89984	0,00016

Tablo 4.21 Uygulama 2'nin eğitim seti 5'e ait sayısal sonuçları

EĞİTİM SETİ 5				
Kiriş Yüğü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-5,85	-5,840368	-0,009632
2	2	-3,25	-3,251728	0,001728
1	3	-3,25	-3,24992	-8E-05
1	4	-4,55	-4,568768	0,018768
1	5	0	-0,001712	0,001712
	6	-2,6	-2,607664	0,007664
	7	1,5	1,502112	-0,002112
	8	-1,3	-1,302432	0,002432
	9	0	-0,000608	0,000608
	10	5,4	5,400336	-0,000336
	11	5,4	5,396864	0,003136
	12	4,2	4,201008	-0,001008
	13	4,2	4,200064	-6,4E-05

Tablo 4.22 Uygulama 2'nin eğitim seti 6'ya ait sayısal sonuçları

EĞİTİM SETİ 6				
Kiriş Yüğü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-4,55	-4,55128	0,00128
1	2	-3,25	-3,255648	0,005648
1,5	3	-3,25	-3,253456	0,003456
1	4	-4,55	-4,544336	-0,005664
1	5	0	0,002496	-0,002496
	6	-1,3	-1,298576	-0,001424
	7	1	0,998976	0,001024
	8	-1,3	-1,29776	-0,00224
	9	0	0,0008	-0,0008
	10	4,2	4,203312	-0,003312
	11	4,2	4,202176	-0,002176
	12	4,2	4,198448	0,001552
	13	4,2	4,198752	0,001248

Tablo 4.23 Uygulama 2'nin eğitim seti 7'ye ait sayısal sonuçları

EĞİTİM SETİ 7				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-5,2	-5,205136	0,005136
1	2	-3,9	-3,894912	-0,005088
2	3	-3,9	-3,896096	-0,003904
1	4	-5,2	-5,209296	0,009296
1	5	0	-0,001152	0,001152
	6	-1,3	-1,298144	-0,001856
	7	1	1,002032	-0,002032
	8	-1,3	-1,303744	0,003744
	9	0	0,002592	-0,002592
	10	4,8	4,797168	0,002832
	11	4,8	4,800608	-0,000608
	12	4,8	4,801008	-0,001008
	13	4,8	4,80032	-0,00032

Tablo 4.24 Uygulama 2'nin eğitim seti 8'e ait sayısal sonuçları

EĞİTİM SETİ 8				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-4,225	-4,203616	-0,021384
1	2	-2,925	-2,928896	0,003896
1	3	-2,925	-2,927472	0,002472
1,5	4	-4,875	-4,875152	0,000152
1	5	0	-0,005664	0,005664
	6	-1,3	-1,304912	0,004912
	7	1,25	1,249296	0,000704
	8	-1,95	-1,948416	-0,001584
	9	0	-0,000928	0,000928
	10	3,9	3,902304	-0,002304
	11	3,9	3,900688	-0,000688
	12	4,5	4,499968	3,2E-05
	13	4,5	4,506208	-0,006208

Tablo 4.25 Uygulama 2'nin eğitim seti 9'a ait sayısal sonuçları

EĞİTİM SETİ 9				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-4,55	-4,564976	0,014976
1	2	-3,25	-3,246864	-0,003136
1	3	-3,25	-3,24752	-0,00248
2	4	-5,85	-5,851056	0,001056
1	5	0	0,002112	-0,002112
	6	-1,3	-1,295952	-0,004048
	7	1,5	1,501248	-0,001248
	8	-2,6	-2,602096	0,002096
	9	0	0,002416	-0,002416
	10	4,2	4,198176	0,001824
	11	4,2	4,200864	-0,000864
	12	5,4	5,400048	-4,8E-05
	13	5,4	5,396848	0,003152

Tablo 4.26 Uygulama 2'nin eğitim seti 10'a ait sayısal sonuçları

EĞİTİM SETİ 10				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-3,9	-3,884896	-0,015104
1	2	-2,6	-2,60072	0,00072
1	3	-2,6	-2,602016	0,002016
1	4	-3,9	-3,88888	-0,01112
1,5	5	0	0,003952	-0,003952
	6	-1,3	-1,30416	0,00416
	7	1	0,999264	0,000736
	8	-1,3	-1,298944	-0,001056
	9	0	-0,003808	0,003808
	10	3,6	3,60856	-0,00856
	11	3,6	3,602	-0,002
	12	3,6	3,611936	-0,011936
	13	3,6	3,601008	-0,001008

Tablo 4.27 Uygulama 2'nin eğitim seti 11'e ait sayısal sonuçları

EĞİTİM SETİ 11				
Kiriş Yüğü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-3,9	-3,905904	0,005904
1	2	-2,6	-2,599632	-0,000368
1	3	-2,6	-2,598784	-0,001216
1	4	-3,9	-3,904384	0,004384
2	5	0	-0,002784	0,002784
	6	-1,3	-1,297456	-0,002544
	7	1	1,00016	-0,00016
	8	-1,3	-1,300448	0,000448
	9	0	0,00248	-0,00248
	10	3,6	3,596176	0,003824
	11	3,6	3,599968	3,2E-05
	12	3,6	3,593584	0,006416
	13	3,6	3,600016	-1,6E-05


Tablo 4.28 Uygulama 2'nin eğitim seti 12'ye ait sayısal sonuçları

EĞİTİM SETİ 12				
Kiriş Yüğü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1,5	1	-5,85	-5,86744	0,01744
1,5	2	-3,9	-3,898512	-0,001488
1,5	3	-3,9	-3,898288	-0,001712
1,5	4	-5,85	-5,8652	0,0152
1,5	5	0	0,000352	-0,000352
	6	-1,95	-1,94808	-0,00192
	7	1,5	1,500656	-0,000656
	8	-1,95	-1,950896	0,000896
	9	0	0,001264	-0,001264
	10	5,4	5,3928	0,0072
	11	5,4	5,395312	0,004688
	12	5,4	5,395232	0,004768
	13	5,4	5,395664	0,004336

Tablo 4.29 Uygulama 2'nin eğitim seti 13'e ait sayısal sonuçları

EĞİTİM SETİ 13				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
2	1	-7,8	-7,732368	-0,067632
2	2	-5,2	-5,200256	0,000256
2	3	-5,2	-5,200304	0,000304
2	4	-7,8	-7,72928	-0,07072
2	5	0	1,6E-05	-1,6E-05
	6	-2,6	-2,600096	9,6E-05
	7	2	1,99992	8E-05
	8	-2,6	-2,59992	-8E-05
	9	0	-0,00016	0,00016
	10	7,2	7,202144	-0,002144
	11	7,2	7,201536	-0,001536
	12	7,2	7,201424	-0,001424
	13	7,2	7,201376	-0,001376


Bu uygulamada da yapay sinir ağının eğitime işlemine ait 13 eğitim seti bulunmaktadır. Eğitime işine ait sayısal sonuçlar incelendiğinde oluşan hata değerlerinin kabul edilebilir sınır içinde kaldığı gözlenmektedir. Yapay sinir ağının bu uygulama için problemi öğrendiği söylenebilir. Eğitim setlerine ait ortalama hata değerleri Şekil 4.8'de yer almaktadır.



Şekil 4.8 Eğitim setlerine ait ortalama hata değerleri.

Şekil 4.8 incelendiğinde ortalama hatanın maksimum değerinin 0,0979 olduğu, ortalama hatanın minimum değerinin 0,0106 olduğu anlaşılmaktadır. Bu uygulamada eğitim setlerinin ortalama hata değerleri 0,0979 ile 0,0106 arasında değişmektedir. Hata değerlerine bakarak yapay sinir ağının bu problem için öğrenme yeteneğinin yüksek olduğu anlaşılmaktadır.


Hatanın iterasyon sayısına bağlı değişimi Şekil 4.9’da yer almaktadır. İterasyon sayısının artması hata oranını azaltmaktadır. 30.000’in üzerindeki iterasyonlarda hatanın azalışı yapay sinir ağının performansını etkilemeyecek kadar azdır. Dolayısıyla bu uygulamada 30.000 iterasyon yeterli görülmüştür.



Şekil 4.9 Hatanın iterasyon sayısına bağlı değişimi

Yapay sinir ağlarında ara katman sayısının belirlenmesi için geliştirilmiş bir kural yoktur. Genellikle deneme yanılma yöntemiyle belirlenmektedir. Sabit ara katman düğüm sayısı (15) ve sabit iterasyon sayısı (30.000) altında ara katman sayısına bağlı hata değişimi Şekil 4.10’ da yer almaktadır. Grafik incelendiğinde ara katman sayısının artması hata oranını belli bir değere kadar azaltmaktadır. Fakat ara katman sayısının artışı yapay sinir ağının performansını etkileyecek hata

azalışını sağlamamaktadır. Bu yüzden uygulamada tek ara katman yeterli görülmüştür.



Şekil 4.10 Sabit ara katman ve iterasyon sayısı altında ara katmana bağlı hata değişimi

Eğitme işlemini takiben yapay sinir ağının adaptif öğrenmesini belirlemek için test işlemine geçilmiştir. Test işlemine ait üç test seti oluşturulmuştur. Test setine ait veriler eğitim setinde olmayan değerlerden oluşmaktadır. Test setine ait giriş değerleri yapay sinir ağına sunularak ağdan uygun sonuçların üretilmesi beklenmektedir. Test setine ait sayısal sonuçlar Tablo 4.30 – 4.32’de yer almaktadır.

Tablo 4.30 Uygulama 2'nin test seti 1'e ait sayısal sonuçları

TEST SETİ 1				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
0,5	1	-1,95	-3,332928	1,382928
0,5	2	-1,3	-1,265264	-0,034736
0,5	3	-1,3	-1,080624	-0,219376
0,5	4	-1,95	-3,501488	1,551488
0,5	5	0	-0,0088	0,0088
	6	-0,65	-0,577008	-0,072992
	7	0,5	0,401328	0,098672
	8	-0,65	-0,577072	-0,072928
	9	0	-0,006368	0,006368
	10	1,8	1,84536	-0,04536
	11	1,8	2,092512	-0,292512
	12	1,8	2,011552	-0,211552
	13	1,8	2,057808	-0,257808

Tablo 4.31 Uygulama 2'nin test seti 2'ye ait sayısal sonuçları


TEST SETİ 2				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
0,75	1	-2,925	-3,550736	0,625736
0,75	2	-1,95	-1,940128	-0,009872
0,75	3	-1,95	-1,872432	-0,077568
0,75	4	-2,925	-3,614304	0,689304
0,75	5	0	-0,002912	0,002912
	6	-0,975	-0,945152	-0,029848
	7	0,75	0,71112	0,03888
	8	-0,975	-0,94488	-0,03012
	9	0	-0,001296	0,001296
	10	2,7	2,758528	-0,058528
	11	2,7	2,84912	-0,14912
	12	2,7	2,819936	-0,119936
	13	2,7	2,835072	-0,135072

Tablo 4.32 Uygulama 2'nin test seti 3'e ait sayısal sonuçları

TEST SETİ 3				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
3	1	-11,7	-7,795312	-3,904688
3	2	-7,8	-6,572768	-1,227232
3	3	-7,8	-6,475984	-1,324016
3	4	-11,7	-7,795776	-3,904224
3	5	0	-0,010768	0,010768
	6	-3,9	-3,56768	-0,33232
	7	3	2,698672	0,301328
	8	-3,9	-3,55704	-0,34296
	9	0	-0,019232	0,019232
	10	10,8	8,010528	2,789472
	11	10,8	8,030512	2,769488
	12	10,8	8,02624	2,77376
	13	10,8	8,029232	2,770768


4.3 Uygulama 3

Uygulamalarda seçilen kafes kirişlerde sistem şekli, ölçü ve yükleme durumlarının benzerlik göstermemesine dikkat edilmiştir. Bu uygulamada seçilen kafes kiriş şekli yarım üçgen sisteme benzemektedir. 9 m. açıklığa ve 2,25 m. yüksekliğe sahip kirişin eğimi %25 'dir. Gerçekte kullanılan kiriş ölçülerine yakın değerler alınmıştır. Seçilen kafes kiriş izostatiktir. Kafes kirişin yükleri diğer iki uygulamada olduğu gibi üst başlığın düğüm noktalarına etkiyen düşey yüklerden oluşmaktadır. Kiriş 4 dış yük etkisinde olup 11 çubuktan oluşan düzlemsel bir sistemdir. Uygulama için seçilen kafes kiriş Şekil 4.11'de yer almaktadır.



Şekil 4.11 Ölçü ve yükleme durumu verilen kafes kiriş.

Yapay sinir ağının modellenmesinde kirişe etkiyen dış yükler ve çubuk kuvvetleri esas alınmaktadır. Bu çalışma için yapay sinir ağı 4 giriş ve 11 çıkışa sahiptir. Kafes kirişin çözümü için oluşturulan yapay sinir ağı modeli Şekil 4.12’de yer almaktadır.



Şekil 4.12 .Kafes kirişin yapay sinir ağı modeli.

Bu uygulamada eğitme işlemi için 7 adet yük kombinasyonu oluşturulmuştur. Kafes kirişin 7 ayrı yük kombinasyonları altında çözümü yapılmıştır. Dolayısıyla yapay sinir ağının eğitme işleminde 7 eğitim seti bulunmaktadır. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. Normalize için çubuk kuvvetleri 8,25 artırılmış ve 17 ye bölünmüştür. Yapay sinir ağı hesabında yaklaşık 30.000 iterasyon yapılmıştır. Bu uygulama için 7 eğitim setine ait giriş yükü, analitik yöntemle bulunan çubuk kuvvetleri ve yapay sinir ağıyla hesaplanan çubuk kuvveti değerleri Tablo 4.33-4.39’da yer almaktadır.

Tablo 4.33 Uygulama 3’ün eğitim seti 1’e ait sayısal sonuçları

EĞİTİM SETİ 1				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2,06	-2,052939	-0,007061
1	2	-4,12	-4,118541	-0,001459
1	3	-4,12	-4,12019	0,00019
1	4	-2	-1,996244	-0,003756
	5	2,5	2,490583	0,009417
	6	-1,5	-1,503006	0,003006
	7	2,24	2,244525	-0,004525
	8	-1	-0,995607	-0,004393
	9	0	-0,000597	0,000597
	10	2	2,00117	-0,00117
	11	4	4,002716	-0,002716

Tablo 4.34 Uygulama 3'ün eğitim seti 2'ye ait sayısal sonuçları

EĞİTİM SETİ 2				
Kiriş Yüğü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1,5	1	-2,06	-2,058243	-0,001757
1	2	-4,12	-4,119595	-0,000405
1	3	-4,12	-4,119833	-0,000167
1	4	-2,5	-2,499172	-0,000828
	5	2,5	2,497706	0,002294
	6	-1,5	-1,500473	0,000473
	7	2,24	2,240955	-0,000955
	8	-1	-0,999075	-0,000925
	9	0	4,9E-05	-4,9E-05
	10	2	1,999895	0,000105
	11	4	4,00054	-0,00054

Tablo 4.35 Uygulama 3'ün eğitim seti 3'e ait sayısal sonuçları

EĞİTİM SETİ 3				
Kiriş Yüğü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2,75	-2,76682	0,01682
1,5	2	-4,81	-4,806208	-0,003792
1	3	-4,81	-4,804219	-0,005781
1	4	-2,33	-2,339168	0,009168
	5	3,33	3,355679	-0,025679
	6	-2	-1,989342	-0,010658
	7	2,24	2,233526	0,006474
	8	-1	-1,009666	0,009666
	9	0	0,000831	-0,000831
	10	2,67	2,671157	-0,001157
	11	4,67	4,671836	-0,001836

Tablo 4.36 Uygulama 3'ün eğitim seti 4'e ait sayısal sonuçları

EĞİTİM SETİ 4				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-3,44	-3,429939	-0,010061
2	2	-5,5	-5,501712	0,001712
1	3	-5,5	-5,502885	0,002885
1	4	-2,67	-2,664905	-0,005095
	5	4,17	4,154968	0,015032
	6	-2,5	-2,505054	0,005054
	7	2,24	2,2441	-0,0041
	8	-1	-0,994655	-0,005345
	9	0	-0,001158	0,001158
	10	3,33	3,32938	0,00062
	11	5,33	5,329345	0,000655

Tablo 4.37 Uygulama 3'ün eğitim seti 5'e ait sayısal sonuçları

EĞİTİM SETİ 5				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2,41	-2,407984	-0,002016
1	2	-5,5	-5,507543	0,007543
1,5	3	-5,5	-5,506268	0,006268
1	4	-2,17	-2,168335	-0,001665
	5	2,92	2,915005	0,004995
	6	-1,75	-1,754164	0,004164
	7	3,35	3,348505	0,001495
	8	-1,5	-1,498314	-0,001686
	9	0	-2E-06	2E-06
	10	2,33	2,328063	0,001937
	11	5,33	5,321542	0,008458


Tablo 4.38 Uygulama 3'ün eğitim seti 6'ya ait sayısal sonuçları

EĞİTİM SETİ 6				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2,75	-2,751537	0,001537
1	2	-6,87	-6,863497	-0,006503
2	3	-6,87	-6,864653	-0,005347
1	4	-2,33	-2,331059	0,001059
	5	3,33	3,33329	-0,00329
	6	-2	-1,997723	-0,002277
	7	4,47	4,470879	-0,000879
	8	-2	-2,001021	0,001021
	9	0	6,6E-05	-6,6E-05
	10	2,67	2,671548	-0,001548
	11	6,67	6,676629	-0,006629

Tablo 4.33 Uygulama 3'ün eğitim seti 7'ye ait sayısal sonuçları


EĞİTİM SETİ 7				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2,06	-2,05996	-4E-05
1	2	-4,12	-4,119714	-0,000286
1	3	-4,12	-4,119731	-0,000269
1,5	4	-2	-2,000018	1,8E-05
	5	2,5	2,500001	-1E-06
	6	-1,5	-1,499742	-0,000258
	7	2,24	2,240122	-0,000122
	8	-1	-1,000197	0,000197
	9	0	-2E-06	2E-06
	10	2	1,999861	0,000139
	11	4	4,000438	-0,000438

Uygulamanın eğitime işlemi için oluşturulan sayısal sonuçlar Tablo 4.5’de verilmiştir. Tablo incelendiğinde hata oranlarının kabul edilebilir sınır içinde kaldığı gözlenmektedir. Eğitim setlerine ait ortalama hata değerleri Şekil 4.13’de yer almaktadır. Şekil 4.13 incelendiğinde 7. eğitim setinin ortalama hatası 0,0007 olup en düşük değerdir. 3. eğitim setinin ortalama hatası ise 0,0364 olup en yüksek değerdir. Uygulamanın eğitime işleminde ortalama hata 0,0007 ile 0,0364 arasında değişmektedir.




Şekil 4.13 Eğitim setlerine ait ortalama hata değerleri

Hatanın iterasyon sayısına bağlı değişimi Şekil 4.14’ de yer almaktadır. İterasyon sayısının artması hatayı azaltmaktadır. Hatanın iterasyon sayısına bağlı değişimi incelenirse hatanın 30.000 iterasyonda 0,000006, 100.000 iterasyonda ise 0,000001 olduğu görülmektedir. Yani 30.000’ den sonraki iterasyonlarda hata azalış miktarı sonuçları etkilemeyecek kadar düşük seviyededir. Dolayısıyla bu uygulamada 30.000 iterasyon yeterli görülmüştür.



Şekil 4.14 Hatanın iterasyon sayısına bağlı değişimi

Uygulamanın eğitme işleminde kullanılan ara katman düğüm sayısı ve iterasyon sayısı sabit tutularak ara katman sayısının değiştirilmesiyle oluşan hatalar Şekil 4.15’de görülmektedir. Ara katman düğüm sayısı 14 ve iterasyon sayısı 30.000 alınmıştır. Ara katman sayısının dörde kadar arttırılması hatayı azaltırken beşinci ara katmanda hata artış göstermektedir. Tek ara katman olması halinde hata 0,000006 iken ara katmanın dörde çıkarılması durumunda hata 0,000001’dir. Ara katman sayısının artışı diğer uygulamalarda olduğu gibi bu uygulamada da hata azalış oranını çok fazla değiştirmemiştir. Bu yüzden tek ara katman yeterli görülmüştür.



Şekil 4.15 Sabit ara katman ve iterasyon sayısı altında ara katmana bağlı hata değişimi

Yapay sinir ağında eğitme işleminde uygun sonuçların elde edilmesinden sonra test işlemine geçilmiştir. Yapay sinir ağının test edilmesi için üç test seti oluşturulmuştur. Eğitim setinde yer almayan giriş değerleri ağa sunularak uygun sonuçların üretilmesi beklenmektedir. Test setine ait sayısal sonuçlar Tablo 4.40-4.42’de yer almaktadır.

Tablo 4.40 Uygulama 3'ün test seti 1'e ait sayısal sonuçları

TEST SETİ 1				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2,06	-2,063088	0,003088
1	2	-4,12	-4,206465	0,086465
1	3	-4,12	-4,204102	0,084102
2	4	-2	-1,983732	-0,016268
	5	2,5	2,498522	0,001478
	6	-1,5	-1,454369	-0,045631
	7	2,24	2,24818	-0,00818
	8	-1	-1,017061	0,017061
	9	0	0,00146	-0,00146
	10	2	1,986193	0,013807
	11	4	4,073164	-0,073164

Tablo 4.41 Uygulama 3'ün test seti 2'ye ait sayısal sonuçları


TEST SETİ 2				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1,5	1	-3,09	-3,037239	-0,052761
1,5	2	-6,18	-5,527365	-0,652635
1,5	3	-6,18	-5,513799	-0,666201
1,5	4	-3	-2,941036	-0,058964
	5	3,75	3,676384	0,073616
	6	-2,25	-2,153545	-0,096455
	7	3,35	3,177179	0,172821
	8	-1,5	-1,461645	-0,038355
	9	0	-0,009624	0,009624
	10	3	2,901677	0,098323
	11	6	5,449297	0,550703

Tablo 4.42 Uygulama 3'ün test seti 3'e ait sayısal sonuçları

TEST SETİ 3				
Kiriş Yükü P_i (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
2	1	-4,12	-3,779289	-0,340711
2	2	-8,25	-6,416992	-1,833008
2	3	-8,25	-6,395725	-1,854275
2	4	-4	-3,633021	-0,366979
	5	5	4,568306	0,431694
	6	-3	-2,652087	-0,347913
	7	4,47	3,941363	0,528637
	8	-2	-1,798925	-0,201075
	9	0	-0,048231	0,048231
	10	4	3,628886	0,371114
	11	8	6,395432	1,604568


4.4 Uygulama 4

Uygulama için seçilen kafes kirişin alt ve üst başlık çubukları birbirine paralel olarak düzenlenmiştir. Alt ve üst başlık çubukları birbirine sadece diyagonallerle bağlanmıştır. 12 m. açıklığa ve 2 m. yüksekliğe sahip kafes kiriş izostatik düzlemsel bir sistemdir. Kiriş üst başlık düğüm noktaları düşey doğrultuda yüklenmiş üç yük etkisindedir. Kafes kiriş sistem şekli ve yükleme durumu simetrik bir sistemdir. Sistemin simetrik olması, dış yüklerin aynı olması halinde ilgili çubuk kuvvetlerinin birbirine eşit olmasını gerektirir. Uygulama için seçilen izostatik düzlemsel kafes kiriş Şekil 4.16'da yer almaktadır.



Şekil 4.16 Ölçü ve yükleme durumu verilen kafes kiriş

Yapay sinir ağının modellenmesinde kirişe etkiyen dış yükler girişleri, çubuk kuvvetleri ise çıkışları oluşturmaktadır. Bu uygulama için yapay sinir ağı 3 giriş ve 11 çıkışa sahiptir. Kafes kirişin çözümü için oluşturulan yapay sinir ağı modeli Şekil 4.17’de yer almaktadır.



Şekil 4.17 Kafes kirişin yapay sinir ağı modeli.

Kafes kiriş 7 yük kombinasyonu altında çözülmüştür. Dolayısıyla yapay sinir ağının eğitme işleminde 7 eğitim seti bulunmaktadır. Diğer uygulamalarda olduğu gibi aktivasyon fonksiyonu olarak sigmoit fonksiyonu kullanılmıştır. Normalize için çubuk kuvvetleri önce 6,36 artırılmış ve 14 ‘e bölünmüştür. Yapay sinir ağı hesabında yaklaşık 30.000 iterasyon yapılmıştır. Bu uygulama için kiriş yükü, analitik çözümden elde edilen çubuk kuvvetleri ve eğitme işlemi sonunda yapay sinir ağıyla hesaplanan çubuk kuvveti değerleri Tablo 4.43-4.49’da görülmektedir.

Tablo 4.43 Uygulama 4'ün eğitim seti 1'e ait sayısal sonuçları

EĞİTİM SETİ 1				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2	-1,992392	-0,007608
1	2	-2	-1,994212	-0,005788
1	3	-2,12	-2,104658	-0,015342
	4	0,707	0,710756	-0,003756
	5	-0,707	-0,706016	-0,000984
	6	-0,707	-0,70701	1E-05
	7	0,707	0,709874	-0,002874
	8	-2,12	-2,107192	-0,012808
	9	1,5	1,497682	0,002318
	10	2,5	2,488476	0,011524
	11	1,5	1,4989	0,0011

Tablo 4.44 Uygulama 4'ün eğitim seti 2'ye ait sayısal sonuçları

EĞİTİM SETİ 2				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1,5	1	-2,33	-2,338542	0,008542
1	2	-2,17	-2,160868	-0,009132
1	3	-2,71	-2,733062	0,023062
	4	0,589	0,58687	0,00213
	5	-0,589	-0,58612	-0,00288
	6	-0,825	-0,82321	-0,00179
	7	0,825	0,823904	0,001096
	8	-2,24	-2,233262	-0,006738
	9	1,92	1,921168	-0,001168
	10	2,75	2,744914	0,005086
	11	1,58	1,580366	-0,000366

Tablo 4.45 Uygulama 4'ün eğitim seti 3'e ait sayısal sonuçları

EĞİTİM SETİ 3				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
2	1	-2,67	-2,662194	-0,007806
1	2	-2,33	-2,329834	-0,000166
1	3	-3,3	-3,28301	-0,01699
	4	0,471	0,472532	-0,001532
	5	-0,471	-0,470634	-0,000366
	6	-0,942	-0,941664	-0,000336
	7	0,942	0,942764	-0,000764
	8	-2,36	-2,356588	-0,003412
	9	2,33	2,32784	0,00216
	10	3	2,994828	0,005172
	11	1,67	1,667992	0,002008

Tablo 4.46 Uygulama 4'ün eğitim seti 4'e ait sayısal sonuçları

EĞİTİM SETİ 4				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2,5	-2,509146	0,009146
1,5	2	-2,5	-2,50335	0,00335
1	3	-2,47	-2,477646	0,007646
	4	1,06	1,055422	0,004578
	5	-1,06	-1,060552	0,000552
	6	-1,06	-1,06093	0,00093
	7	1,06	1,057914	0,002086
	8	-2,47	-2,468742	-0,001258
	9	1,75	1,74628	0,00372
	10	3,25	3,268052	-0,018052
	11	1,75	1,745258	0,004742

Tablo 4.47 Uygulama 4'ün eğitim seti 5'e ait sayısal sonuçları

EĞİTİM SETİ 5				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-3	-2,994372	-0,005628
2	2	-3	-2,993896	-0,006104
1	3	-2,83	-2,82465	-0,00535
	4	1,41	1,412856	-0,002856
	5	-1,41	-1,40841	-0,00159
	6	-1,41	-1,409124	-0,000876
	7	1,41	1,411904	-0,001904
	8	-2,83	-2,82304	-0,00696
	9	2	2,00031	-0,00031
	10	4	3,98544	0,01456
	11	2	2,000842	-0,000842


Tablo 4.48 Uygulama 4'ün eğitim seti 6'ya ait sayısal sonuçları

EĞİTİM SETİ 6				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2,17	-2,164018	-0,005982
1	2	-2,33	-2,337898	0,007898
1,5	3	-2,24	-2,237266	-0,002734
	4	0,825	0,824352	0,000648
	5	-0,825	-0,825926	0,000926
	6	-0,589	-0,588024	-0,000976
	7	0,589	0,587206	0,001794
	8	-2,71	-2,731648	0,021648
	9	1,58	1,58332	-0,00332
	10	2,75	2,749408	0,000592
	11	1,92	1,921854	-0,001854

Tablo 4.49 Uygulama 4'ün eğitim seti 7'ye ait sayısal sonuçları


EĞİTİM SETİ 7				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	-2,33	-2,333096	0,003096
1	2	-2,67	-2,663356	-0,006644
2	3	-2,36	-2,361082	0,001082
	4	0,942	0,942316	-0,000316
	5	-0,942	-0,941034	-0,000966
	6	-0,471	-0,47153	0,00053
	7	0,471	0,472196	-0,001196
	8	-3,3	-3,283836	-0,016164
	9	1,67	1,66746	0,00254
	10	3	2,999154	0,000846
	11	2,33	2,328036	0,001964

Uygulamanın eğitime işleminde oluşturulan 7 eğitim setine ait sayısal sonuçlar Tablo 4.7'de verilmiştir. Diğer uygulamalarda olduğu gibi oluşan hata oranlarının kabul edilebilir sınır içerisinde yer aldığı gözlenmektedir. Hata değerlerine bakarak yapay sinir ağının problemi öğrenme yeteneğinin yüksek olduğu söylenebilir. Eğitim setlerine ait ortalama hata değerleri Şekil 4.18'de yer almaktadır. Grafik incelendiğinde 2. eğitim setinin ortalama hatası 0,0279 ile maksimum seviyede iken 7. eğitim setinin ortalama hatası 0,0182 ile en düşük seviyededir. Ortalama hata değerleri bu uygulamada yakın değerler içermektedir.




Şekil 4.18 Eğitim setlerine ait ortalama hata değerleri.

Hatanın iterasyon sayısına bağlı değişimi Şekil 4.19’ da görülmektedir. İterasyon sayısının artması hata oranını azaltmaktadır. Bu uygulamada 30.000 iterasyonda 0,000009 hata oluşurken 100000 iterasyonda 0,000005 hata gözlenmektedir. 30.000’in üzerindeki iterasyonlarda hatanın azalışı sonucu etkilemeyecek seviyededir. Bu yüzden çalışmada 30.000 iterasyon yeterli görülmüştür.



Şekil 4.19 Hatanın iterasyon sayısına bağlı değişimi

Yapay sinir ağlarında uygun ara katman sayısının seçilmesi belirsizlik içermektedir. Uygulamanın eğitime işleminde kullanılan ara katman düğüm sayısı ve iterasyon sayısı sabit tutularak ara katman sayısının değişimine bağlı hata değerleri Şekil 4.20’de yer almaktadır. Ara katman sayısının üçe kadar artırılması hatayı azaltırken, üçün üzerine çıkarılması hatayı artırmaktadır. Bu uygulamada en uygun ara katman sayısının üç olduğu gözlenmektedir. Fakat ara katman sayısının artışına bağlı hata azalışı önemszenmeyecek seviyededir. Dolayısıyla tek ara katman yeterli görülmüştür.



Şekil 4.20 Sabit ara katman ve iterasyon sayısı altında ara katmana bağlı hata değişimi

Eğitime işleminde yapay sinir ağının performansı oldukça yüksek seviyededir. Yapay sinir ağının öğrenme işlemi için gerçek performansı test setine ait sayısal sonuçlara bağlıdır. Test işlemi için üç test seti oluşturulmuştur. Test setlerine ait sayısal sonuçlar Tablo 4.50-4.52’de yer almaktadır.

Tablo 4.50 Uygulama 4'ün test seti 1'e ait sayısal sonuçları

TEST SETİ 1				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1,5	1	-3	-2,950426	-0,049574
1,5	2	-3	-2,932996	-0,067004
1,5	3	-3,18	-3,161448	-0,018552
	4	1,06	1,030292	0,029708
	5	-1,06	-1,052586	-0,007414
	6	-1,06	-1,05015	-0,00985
	7	1,06	1,0467	0,0133
	8	-3,18	-3,145614	-0,034386
	9	2,25	2,21906	0,03094
	10	3,75	3,707666	0,042334
	11	2,25	2,232136	0,017864

Tablo 4.51 Uygulama 4'ün test seti 2'ye ait sayısal sonuçları


TEST SETİ 2				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
2	1	-4	-3,695254	-0,304746
2	2	-4	-3,674268	-0,325732
2	3	-4,24	-3,945392	-0,294608
	4	1,41	1,346104	0,063896
	5	-1,41	-1,36599	-0,04401
	6	-1,41	-1,365542	-0,044458
	7	1,41	1,39201	0,01799
	8	-4,24	-3,949928	-0,290072
	9	3	2,841318	0,158682
	10	5	4,66717	0,33283
	11	3	2,914062	0,085938

Tablo 4.52 Uygulama 4'ün test seti 3'e ait sayısal sonuçları

TEST SETİ 3				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
3	1	-6	-4,623776	-1,376224
3	2	-6	-4,620808	-1,379192
3	3	-6,36	-4,856344	-1,503656
	4	2,12	1,915456	0,204544
	5	-2,12	-1,848374	-0,271626
	6	-2,12	-1,851818	-0,268182
	7	2,12	2,024166	0,095834
	8	-6,36	-4,951026	-1,408974
	9	4,5	3,74954	0,75046
	10	7,5	5,848938	1,651062
	11	4,5	4,026852	0,473148


4.5 Uygulama 5

Son uygulamada kafes kiriş olarak sistem şekli bakımından direk düşürülmüştür. Önceki uygulamalarda yükler kirişe düşey olarak etkimektedir. Bu uygulamada kiriş yatay ve düşey yük etkisindedir. Eğik yükün yapay sinir ağının eğitimde öğrenmeyi nasıl etkilediği araştırılacaktır. 3m. açıklığa ve 3m. yüksekliğe sahip kafes kiriş diğer uygulamalarda olduğu gibi izostatiktir. Düzlemsel olan sistem 13 çubuktan oluşmaktadır. Uygulama için seçilen kafes kiriş Şekil 4.21'de yer almaktadır.



Şekil 4.21 Ölçü ve yükleme durumu verilen kafes kiriş şekli

Kafes kirişin yapay sinir ağıyla modellenmesinde kiriş yükü ve çubuk kuvvetleri dikkate alınmaktadır. Bu çalışmada kirişe etkiyen 5 dış yük ve 13 çubuk kuvveti bulunmaktadır. Dolayısıyla ağ 5 giriş ve 13 çıkışa sahiptir. Önceki uygulamalarda olduğu gibi bu uygulamada da tek ara katman kullanılmıştır. Kafes kirişin çözümü için geliştirilen yapay sinir ağı modeli Şekil 4.22’de görülmektedir.



Şekil 4.22 Kafes kirişin yapay sinir ağı modeli

Yapay sinir ağının eğitiminde 8 adet eğitim seti kullanılmıştır. Çok katmanlı algılayıcı modelinden yararlanılmıştır. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanıldığı için çubuk kuvveti değerlerinin 0-1 arasında normalize edilmesi gerekmektedir. Normalize işlemi için çubuk kuvvetleri 6,32 artırılmış ve 13'e bölünmüştür. Yapay sinir ağı hesabında yaklaşık 30.000 iterasyon yapılmıştır. Bu uygulamada eğitme işlemi sonunda bulunan sonuçlar Tablo 4.53-4.60' da yer almaktadır.

Tablo 4.53 Uygulama 5'in eğitim seti 1'e ait sayısal sonuçları

EĞİTİM SETİ 1				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	3	2,984763	0,015237
1	2	2	1,995151	0,004849
1	3	1	0,999182	0,000818
1	4	0	-0,000414	0,000414
1	5	1	1,000508	-0,000508
	6	0	0,000613	-0,000613
	7	-0,66	-0,657798	-0,002202
	8	-1	-1,002155	0,002155
	9	-0,33	-0,330991	0,000991
	10	0	0,00164	-0,00164
	11	-3,16	-3,138874	-0,021126
	12	-2,11	-2,105842	-0,004158
	13	-1,05	-1,049241	-0,000759

Tablo 4.54 Uygulama 5'in eğitim seti 2'ye ait sayısal sonuçları

EĞİTİM SETİ 2				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1,5	1	3,5	3,495871	0,004129
1	2	2,5	2,498043	0,001957
1	3	1,5	1,498967	0,001033
1	4	0	4,1E-05	-4,1E-05
1	5	1,5	1,499734	0,000266
	6	0,33	0,329864	0,000136
	7	-0,5	-0,498522	-0,001478
	8	-1,33	-1,330678	0,000678
	9	-0,5	-0,499991	-9E-06
	10	0	-0,000154	0,000154
	11	-3,69	-3,684783	-0,005217
	12	-2,64	-2,638504	-0,001496
	13	-1,58	-1,580967	0,000967

Tablo 4.55 Uygulama 5'in eğitim seti 3'e ait sayısal sonuçları

EĞİTİM SETİ 3				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
2	1	4	3,993628	0,006372
1	2	3	2,996489	0,003511
1	3	2	1,999532	0,000468
1	4	0	8E-05	-8E-05
1,5	5	1,5	1,498798	0,001202
	6	0,16	0,159876	0,000124
	7	-0,83	-0,828761	-0,001239
	8	-1,67	-1,669835	-0,000165
	9	-0,67	-0,670265	0,000265
	10	0	0,000964	-0,000964
	11	-4,22	-4,21374	-0,00626
	12	-3,16	-3,156658	-0,003342
	13	-2,11	-2,109222	-0,000778

Tablo 4.56 Uygulama 5'in eğitim seti 4'e ait sayısal sonuçları

EĞİTİM SETİ 4				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	3,5	3,508325	-0,008325
1,5	2	2,5	2,506285	-0,006285
1	3	1	0,999364	0,000636
1	4	0	0,001185	-0,001185
1	5	1,33	1,330708	-0,000708
	6	0,16	0,157302	0,002698
	7	-0,66	-0,663544	0,003544
	8	-1,17	-1,164161	-0,005839
	9	-0,33	-0,32817	-0,00183
	10	0	0,001341	-0,001341
	11	-3,69	-3,705622	0,015622
	12	-2,64	-2,646343	0,006343
	13	-1,05	-1,045016	-0,004984

Tablo 4.57 Uygulama 5'in eğitim seti 5'e ait sayısal sonuçları

EĞİTİM SETİ 5				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	4	3,985074	0,014926
2	2	3	2,992498	0,007502
1	3	1	0,998727	0,001273
1	4	0	-0,000414	0,000414
1	5	1,67	1,669098	0,000902
	6	0,33	0,330748	-0,000748
	7	-0,66	-0,656472	-0,003528
	8	-1,33	-1,332602	0,002602
	9	-0,33	-0,3309	0,0009
	10	0	0,000574	-0,000574
	11	-4,22	-4,199479	-0,020521
	12	-3,16	-3,152862	-0,007138
	13	-1,05	-1,051269	0,001269

Tablo 4.58 Uygulama 5'in eğitim seti 6'ya ait sayısal sonuçları

EĞİTİM SETİ 6				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	3,5	3,512472	-0,012472
1	2	2	1,997426	0,002574
1,5	3	1	1,001275	-0,001275
1	4	0	-0,000271	0,000271
1	5	1,17	1,166011	0,003989
	6	0	0,000561	-0,000561
	7	-0,66	-0,660281	0,000281
	8	-1	-0,999464	-0,000536
	9	-0,33	-0,33012	0,00012
	10	0	-0,001597	0,001597
	11	-3,69	-3,711095	0,021095
	12	-2,11	-2,106674	-0,003326
	13	-1,05	-1,051438	0,001438


Tablo 4.59 Uygulama 5'in eğitim seti 7'ye ait sayısal sonuçları

EĞİTİM SETİ 7				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	4	3,98861	0,01139
1	2	2	2,000156	-0,000156
2	3	1	0,998714	0,001286
1	4	0	0,000288	-0,000288
1	5	1,33	1,332151	-0,002151
	6	0	-0,000739	0,000739
	7	-0,66	-0,659423	-0,000577
	8	-1	-0,999854	-0,000146
	9	-0,33	-0,329808	-0,000192
	10	0	0,001627	-0,001627
	11	-4,22	-4,202495	-0,017505
	12	-2,11	-2,110717	0,000717
	13	-1,05	-1,048253	-0,001747

Tablo 4.60 Uygulama 5'in eğitim seti 8'e ait sayısal sonuçları

EĞİTİM SETİ 8				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	3	2,999245	0,000755
1	2	2	1,999974	2,6E-05
1	3	1	0,999676	0,000324
1,5	4	0	6,7E-05	-6,7E-05
1,5	5	0,5	0,500268	-0,000268
	6	-0,5	-0,499965	-3,5E-05
	7	-1,17	-1,169569	-0,000431
	8	-1	-1,000231	0,000231
	9	-0,33	-0,329977	-2,3E-05
	10	0	-0,000219	0,000219
	11	-3,16	-3,158868	-0,001132
	12	-2,11	-2,109989	-1,1E-05
	13	-1,05	-1,050567	0,000567


Son uygulamanın eğitme işlemine ait sayısal sonuçlar Tablo 4.9’da verilmiştir. Diğer uygulamalarda olduğu gibi bu uygulamada da eğitme işlemine ait hata değerleri yapay sinir ağının öğrenme yeteneğinin yüksek olduğunu göstermektedir. Hata değerlerini ayrıntılı görebilmek için uygulamadaki eğitim setlerine ait ortalama hata değerleri Şekil 4.23’de yer almaktadır.



Şekil 4.23 Eğitim setlerine ait ortalama hata değerleri.


Grafik incelendiğinde en yüksek hatanın 0,0279 değeriyle 5. eğitim setine ait olduğu, en düşük hatanın ise 0,0016 değeriyle 8. eğitim setine ait olduğu görülmektedir. Eğitim setlerine ait ortalama hataların 0,0016 ile 0,0279 değerleri arasında yer aldığı gözlenmektedir. Uygulamanın eğitim setlerine ait ortalama hata değerleri yapay sinir ağının eğitimini başarıyla tamamladığını göstermektedir.

Hatanın iterasyon sayısına bağlı değişimi Şekil 4.24’de görülmektedir. İterasyon sayısının artması hata oranını azaltmaktadır. Bu uygulamada 30.000 iterasyonda 0,000007 hata oluşurken 100.000 iterasyonda 0,000002 hata gözlenmektedir. 30.000’in üzerindeki iterasyonlarda hata azalış oranı sonucu etkilemeyecek seviyededir. Bu yüzden çalışmada 30.000 iterasyon yeterli görülmüştür.



Şekil 4.24 Hatanın iterasyon sayısına bağlı değişimi

Yapay sinir ağlarında belirsizlik içeren parametrelerden birisi de ara katman sayısıdır. Uygun ara katman sayısının seçilmesi genelde deneme yanılma yöntemiyle gerçekleşmektedir. Uygulamanın eğitime işleminde kullanılan ara katman düğüm sayısı ve iterasyon sayısı sabit tutularak ara katman sayısının değişimine bağlı hata değişimi Şekil 4.25’de yer almaktadır. Ara katman düğüm sayısı 14 ve iterasyon sayısı 30.000 alınmıştır. Ara katman sayısının üçün üzerine çıkarılması hatayı artırmaktadır. Ara kaman sayısının artırılmasına bağlı hata azalış oranının sonucu etkileyecek seviye olmadığı gözlenmiştir. Bu yüzden uygulamada tek ara katman yeterli görülmüştür.



Şekil 4.25 Sabit ara katman ve iterasyon sayısı altında ara katmana bağlı hata değişimi

Yapay sinir ağlarında adaptif öğrenme test işlemi sonrasında anlaşılmaktadır. Yapay sinir ağı eğitme sırasında oluşturduğu ağırlık değerleriyle ağa sunulan farklı veri girişi için uygun sonuçları üretmektedir. Test işlemi için bu uygulamada da üç test seti oluşturularak ağın performansı belirlenmeye çalışılmıştır. Test işlemi sonucunda elde edilen sayısal sonuçlar Tablo 4.61-4.63’de yer almaktadır.

Tablo 4.61 Uygulama 5'in test seti 1'e ait sayısal sonuçları

TEST SETİ 1				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1	1	3	2,999362	0,000638
1	2	2	1,999493	0,000507
1	3	1	0,99952	0,00048
2	4	0	0,000223	-0,000223
2	5	0	0,500281	-0,500281
	6	-1	-0,500121	-0,499879
	7	-1,67	-1,169504	-0,500496
	8	-1	-1,000309	0,000309
	9	-0,33	-0,329483	-0,000517
	10	0	-0,000453	0,000453
	11	-3,16	-3,157906	-0,002094
	12	-2,11	-2,11047	0,00047
	13	-1,05	-1,051139	0,001139

Tablo 4.62 Uygulama 5'in test seti 2'ye ait sayısal sonuçları

TEST SETİ 2				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
1,5	1	4,5	3,074112	1,425888
1,5	2	3	2,08151	0,91849
1,5	3	1,5	1,019046	0,480954
1,5	4	0	0,005202	-0,005202
1,5	5	1,5	0,111165	1,388835
	6	0	-0,864342	0,864342
	7	-1	-1,558529	0,558529
	8	-1,5	-1,060564	-0,439436
	9	-0,5	-0,364843	-0,135157
	10	0	0,003616	-0,003616
	11	-4,74	-3,236543	-1,503457
	12	-3,16	-2,192513	-0,967487
	13	-1,58	-1,147599	-0,432401

Tablo 4.63 Uygulama 5'in test seti 3'e ait sayısal sonuçları

TEST SETİ 3				
Kiriş Yükü Pi (KN)	Çubuk No	Çubuk Kuvvetleri (KN)	YSA Degerleri	Fark
2	1	6	5,061396	0,938604
2	2	4	3,422837	0,577163
2	3	2	1,85739	0,14261
2	4	0	-0,074566	0,074566
2	5	2	1,711582	0,288418
	6	0	-0,099175	0,099175
	7	-1,33	-1,36765	0,03765
	8	-2	-1,824938	-0,175062
	9	-0,66	-0,55554	-0,10446
	10	0	-0,018679	0,018679
	11	-6,32	-5,216105	-1,103895
	12	-4,22	-3,705674	-0,514326
	13	-2,11	-1,767595	-0,342405

5. DEĞERLENDİRME

Bu çalışmada yapay sinir ağları kullanılarak izostatik kafes sistemlerin analizi ve tasarımıdaki uygulamalar incelenmiştir. Yapay sinir ağının kafes kirişlerin çözümü üzerindeki etkinliğini araştırmak için beş farklı uygulama yapılmıştır. Her uygulamada sistem şekli, açıklık ve yükleme durumu farklı izostatik düzlemsel kafes kiriş seçilmiştir.

Uygulamalarda iterasyon sayısının artışı hata oranını azaltmaktadır. Yapay sinir ağı hesabında oluşabilecek en düşük hata değerinin % 0,10 olduğu gözlenmektedir. Her uygulamada 30.000 iterasyon yapılmış olup uygulamalarda oluşan hata oranları yukarıda yer almaktadır. 30.000'in üzerindeki iterasyonlarda hata azalış oranı ağı performansı etkilemeyecek kadar azdır. Bu yüzden her uygulamada 30.000 iterasyon yeterli görülmüştür.

Yapay sinir ağında ara katman sayısının belirlenmesi için geliştirilmiş bir kural yoktur. Genellikle deneme yanılma yöntemiyle belirlenmektedir. Uygun ara katman sayısının belirlenmesine yönelik sabit ara katman düğüm sayısı ve sabit iterasyon sayısı altında ara katman sayısı artırılarak hata değerleri hesaplanmıştır.

1. ve 2. uygulamada hata azalış gösterirken diğer üç uygulamada ise hata artış göstermektedir. 1. ve 2. uygulamada ara katman sayısının artışı yapay sinir ağının performansını etkileyecek hata azalışını sağlamamaktadır. Bu yüzden uygulamalarda tek ara katman yeterli görülmüştür.

Yapay sinir ağının problemi öğrenmesi için her uygulamada çok sayıda eğitim ve test seti oluşturulmuştur. Eğitim işlemi sonunda yapay sinir ağı 1.ve 2. uygulamada % 0,48 hata, 3. uygulamada %0,25 hata, 4. uygulamada %0,30 hata, 5. uygulamada %0,26 hata ile eğitimini tamamlamıştır. Ayrıca uygulamalarda her eğitim setinin ortalama hatası da hesaplanmıştır. Eğitim setlerine ait en düşük ortalama hatanın 0,0005 değeri ile 1.uygulamaya, en yüksek ortalama hatanın 0,0979 değeri ile 2. uygulamaya ait olduğu görülmektedir. Gerek uygulamalara ait toplam hata değerleri, gerekse eğitim setlerinin ortalama hatası kabul edilebilir sınır içerisinde kalmaktadır. Oluşan hata değerleri incelendiğinde yapay sinir ağının kafes kirişler üzerindeki öğrenme yeteneğinin yüksek olduğu anlaşılmaktadır.

6. SONUÇ

Bu çalışmada yapay sinir ağlarının kafes sistem analizi ve tasarımındaki uygulamalar incelenmiştir. Çok katmanlı geri yayımlı yapay sinir ağı modeli tercih edilerek hesaplar bu modele göre yapılmıştır. Kafes sistemlerin analizi ve tasarımı yapay sinir ağının etkinliğinin araştırılmasına yönelik beş farklı uygulama yapılmıştır. Uygulamalarda izostatik düzlemsel kafes giriş seçilmiştir. Her uygulamada kafes girişin sistem şekli, açıklık ve yükleme durumu değiştirilmiştir. Bu sayede değişik kafes girişlerin çözümünde yapay sinir ağının sistem üzerindeki performansının ne ölçüde olduğu belirlenmeye çalışılmıştır.

Uygulamalarda kafes sistemlerin çubuk kuvveti değeri belirlenmektedir. Kafes sistemin yapay sinir ağı modeli oluşturulduktan sonra hazır bilgisayar programı ile çözümü yapılmıştır. Analitik çözümden ve yapay sinir ağı ile elde edilen sayısal sonuçlar birbiri ile karşılaştırılarak incelenmiştir .

Yapay sinir ağlarının kafes sistemlerde kullanılabilirliği araştırılmıştır. Her uygulama için yapay sinir ağının problemi öğrenmesine yetecek sayıda eğitim ve test seti oluşturulmuştur. Test setine ait veriler eğitim setinde yer almayan değerlerden oluşmaktadır. Yapay sinir ağının eğitime işlemine ait sonuçlar, test işlemine göre daha etkin düzeydedir. Eğitime ve test setlerine ait değerler kafes sistemlerin analizi ve tasarımı yapay sinir ağlarının kullanılabilirliğini göstermektedir.

Yapay sinir ağları eksik bilgi ile çalışabildiği gibi probleme ait yeni verilerin ağı ilave edilmesiyle sistemin modeli değiştirilebilmektedir. Bu sayede yapay sinir ağlarının probleme uyarlanabilirliği kolaylaşmaktadır. Diğer matematiksel modellerde uygun çözümün üretilmesi için programa ait parametrelerin eksiksiz olarak sisteme girilmesi gerekmektedir. Bu durum yapay sinir ağlarını matematiksel modellerden ayıran önemli özelliklerden birisidir.

Mühendislik problemlerinde yapay sinir ağı modelinin oluşturulmasında malzeme davranışı önem taşımaktadır. Kafes sistemleri oluşturan çubuklar sadece eksenel yük etkisindedir. Düğüm noktalarının mafsallı olarak düzenlendiği kafes sistemlerin yapay sinir ağları ile modellenmesi kolayca yapılmaktadır.

Yapay sinir ağlarının kullanımı gün geçtikçe artmaktadır. Günümüzde pek çok meslek alanında yapay sinir ağları kullanılarak başarılı sonuçların elde edildiği

alıřmalar yer almaktadır. Fakat en iyi sonuca ulařıldığının kesin olarak bilinmemesi sebebiyle yapay sinir aęlarının her trl hesaplamalarda kullanılabilecek uygun bir yntem olduęunu sylemek doęru deęildir. Matematiksel modellerle zm g olan, giriř ve ıkıř deęerleri arasında iliřki kurmanın zor olduęu yaklařımlarda ve doęrusal olmayan problemlerin zmnde yapay sinir aęları uygun bir hesaplama yntemidir.

KAYNAKLAR

- Alp, M., Cıgızoglu, H. K., 2004, “ Farklı Yapay Sinir Ağı Metodları ile Yağış - Akış İlişkisinin Modellenmesi ” , İTÜ Mühendislik Dergisi, cilt : 6, sayı: 1,80 -88
- Armutcu M., 1997, “ Çelik Çerçevelerin Genetik Algoritma ile Optimizasyonu ”, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon
- Aydoğmuş, Z., Çöteli, R., 2005, “Yapay Sinir Ağları Yardımıyla İzalator Yüzeyinde Potansiyel Tahmini”, Fırat Üniversitesi, Fen ve Mühendislik Bilimleri Dergisi, 239 -246
- Baylar, A.,Emiroğlu, M. E., Arslan, A., 1999, “ Geriye Yayılma Yapay Sinir Ağı Kullanılarak Yanal Su Alma Yapısına Yönelecek Olan Sürüntü Maddesi Oranının Bulunması”, Dokuz Eylül Üniversitesi, Fen ve Mühendislik Dergisi, cilt: 1, sayı: 2, 1 -12
- Civalek, Ö., Çatal, H. H., 2004, “Geriye Yayılma Yapay Sinir Ağları Kullanarak Elastik Kirişlerin Statik ve Dinamik Analizi”, Dokuz Eylül Üniversitesi, Fen ve Mühendislik Dergisi, cilt:6, sayı:1, 1 -16
- Civalek, Ö., Ülker, M., 2004, “Dikdörtgen Plakların Doğrusal Olmayan Analizinde Yapay Sinir Ağı Yaklaşımı”, İMO Teknik Dergi, 3171 -3190
- Dere Y., 1997, “ Yapı Analizi ve Tasarımında Yapay Sinir Ağları”, Yüksek Lisans Tezi, Selçuk Üniversitesi , Fen Bilimleri Enstitüsü, Konya
- Efe M. Ö., Kaynak O., 2004, “Yapay Sinir Ağları ve Uygulamaları”, Boğaz İçi Üniversitesi Yayınları, İstanbul
- Elmas Ç., 2003, “ Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)”, Seçkin Yayıncılık, Ankara
- Fırat, M., Güngör, M., 2004, “ Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağıyla Belirlenmesi”, İMO Teknik Dergisi, 3267 -3282
- Göktepe,A. B., Açar, E., Lav, A.H.,2005, “ Esnek Üst Yapılarda Mekanik Özelliklerin Yapay SINIR Ağları Kullanılarak Geri Hesaplanması”, İTÜ Dergisi, cilt:4, sayı:2, 31 -42
- Keleşoğlu, Ö., Ekinci,C. E., Fırat, A., 2005, “Yalıtım Hesaplarında Yapay Sinir Ağlarının Kullanımı”, Mühendislik ve Fen Bilimleri Dergisi

Koç, M. L., Balas, C. E., Arslan, A., 2004, “ Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı”İMO Teknik Dergi,3351 -3375

Öztemel E., 2003, “ Yapay Sinir Ağları”, Papatya Yayıncılık , İstanbul

SAP 2000, CSI (computers and structures, inc.), Ocak 2001,İngilizce, Computers & Engineering, Almanya

Terzi, S., Karaşahin, M., 2004, “Yapay Sinir Ağları Yöntemi ile Esnek Üstyapı Performans Tahmin Modeli Geliştirilmesi”, 4. Ulusal Asfalt Sempozyumu,Bildirileri Kitabı,Ankara, 344 -357