

1. GİRİŞ

Bilim dünyası 1940'lı yıllarda yapay sinir ağları ile tanıştı. Bu alanda yapılan ilk çalışmalar beyin hücrelerinin işlevlerinin ve birbirleri ile haberleşme şekillerinin ortaya çıkarılmasını amaçlamaktaydı. O zamandan beri yapay sinir ağları gerek teorik gerekse pratik anlamda dikkate değer miktarda yol katetti. Bugün birçok hücrenin belli bir düzende bir araya getirilmesi ve uygun öğrenme algoritmalarının kullanılması ile sinir ağları kurulabilmekte ve bu ağlar çok karmaşık görevleri başarıyla yerine getirebilmektedir [1].

Bilgisayar teknolojisindeki gelişmeler farklı analiz tekniklerinin ortaya çıkmasını sağlamıştır. Bu tekniklerden biri olan yapay zekâ insan beyninin çalışma biçimini model edinen bir uygulamadır. 1990'lı yıllardan beri bilgisayarların öğrenmesini sağlayan Yapay Sinir Ağları teknolojisinde oldukça hızlı bir gelişme görüldü. Bu teknoloji, kısa zamanda araştırmacıların dikkatlerini üzerine çeken bir bilim dalı olmayı başardı ve elde edilen başarılar hem yapay sinir ağlarının önemini hem de bu sistemlere olan ilgiyi artırmaktadır. Bilgisayar, endüstri, tıp, ekonomi ve askeri uygulamalarda başarıyla kullanılan bu teknik, yapı mühendisliğinde de kullanılmaya başlanmıştır [2].

Sinir ağları insan beynindeki nöronlara benzer olarak çalışan karmaşık sistemlerdir. Yani, bu ağlar insan beyninin biyolojik fonksiyonlarının basit bir modellenmesinden ibarettir. Ağ, kendisine sunulan veriler arasında bağlantılar kurarak problemi öğrenmekte, deneysel sonuçları depolamakta ve bunları kullanıma hazırlamaktadır [3].

Yapay sinir ağları, insan beyninin temel birimi olan nöronlara benzer olarak teşkil edilen yapay nöronların farklı topoloji ve ağ modelleriyle birbirine bağlanmasıyla oluşan karmaşık sistemlerdir. Bir yapay sinir ağı, birbiriyle etkileşim içindeki pek çok yapay nöronun paralel bağlı bir hiyerarşik organizasyonudur [4]. Yapay sinir ağında hesaplama algoritmik programlamaya bir seçenek oluşturan, temel olarak yeni ve farklı bir bilgi işleme tekniğidir. Programda adım adım yürütülen bir yöntemin verilmesi yerine sinirsel ağ ilişkilendirmeyi yapan iç kurallarını kendi üretir ve bu kuralları, sonuçları örneklerle karşılaştırarak düzenler [5].

Yapay sinir ağları bilinen hesaplama yöntemlerinden farklı bir hesaplama yöntemi önermektedir. Bulundukları ortama uyum sağlayan, adaptif, eksik bilgi ile çalışabilen, belirsizlikler altında karar verebilen, hatalara karşı toleranslı olan bu hesaplama yönteminin hayatın hemen hemen her alanında başarılı uygulamalarını görmek mümkündür. Oluşturulacak olan ağı yapısının belirlenmesinde, ağ parametrelerinin seçiminde, belirli bir standardın olmaması, problemlerin sadece nümerik bilgiler ile gösterilebilmesi, eğitimin nasıl bitirileceğinin bilinmemesi ve ağı davranışlarını açıklayamamasına rağmen bu ağlara olan ilgi her geçen gün artmaktadır. Özellikle sınıflandırma, örüntü tanıma, sinyal filtreleme, veri

sıkıştırma ve optimizasyon çalışmalarında yapay sinir ağıları en güçlü teknikler arasında sayılabilir. Veri madenciliği, optik karakter taşıma, optimum rota belirleme, parmak izi tanıma, malzeme analizi, iş çizelgelemesi ve kalite kontrol, tıbbi analiz gibi birçok alanda günlük hayatımızda göreceğimiz başarılı örneklerine rastlamak mümkündür [6].

Biyolojik sinirlerden esinlenerek elde edilen YSA, doğrusal olmayan ve paralel bilgi işleme özellikleriyle; bulunduğu ortamın değişmesiyle cevaptaki davranışı değiştirebilme, giriş uyarılarındaki küçük değişimleri tolere edebilme, değişik bazı uyarılar karşısında daha önceki uyarılar arasından benzer özellikler keşfederek deneyimi olmadığı halde uyarıyı cevaplayabilme gibi üstün özelliklere sahiptir [7, 8].

Bu tezde yapay sinir ağlarının yapısal sistemlere uygulanması incelenmiştir. Tez genel olarak dört bölümden oluşmaktadır. Birinci bölüm giriş bölümü olup genel olarak sinir ağlarına değinilmiştir. İkinci bölümde, yapay sinir ağları tanıtılmış, yapay sinir ağlarının avantajları ve dezavantajları, genel özellikleri, öğrenme yöntemleri, öğrenme kuralları ve ağ çeşitleri verilmiştir. Üçüncü bölüm de ise yapay sinir ağları yapısal sistemlere uygulanmış ve sayısal örnekler detaylı bir şekilde anlatılmıştır. Dördüncü bölüm sonuç bölümü olarak sunulmuştur.

2. YAPAY SİNİR AĞLARI

2.1. Yapay Sinir Ağlarının Tarihsel Gelişimi

İnsan davranışlarını taklit etmek amacıyla geliştirilen yapay zekâ uygulamalarının bir alt dalı olan yapay sinir ağları, ortaya çıkışından günümüze değin birçok aşamalardan geçmiş ve son yıllardaki teknolojik gelişime paralel olarak gelişimini çok hızlı bir şekilde devam ettirmektedir.

Yapay sinir ağlarının tarihçesi nörobiyoloji konusuna insanların ilgi duyması ve elde ettikleri bilgileri bilgisayar bilimine uygulamaları ile başlamaktadır. Yapay sinir ağları ile ilgili çalışmaları 1970 öncesi ve sonrası diye ikiye ayırmak gerekmektedir. Çünkü 1970 yılında bu bilimin tarihinde bir önemli dönüm noktası başlamış ve o zamana kadar olmaz diye düşünülen birçok sorun çözülmüş ve yeni gelişmeler başlamıştır. Her şey bitti derken yapay sinir ağları yeniden doğmuştur [6].

1943 yılında McCulloch ve Pitts'in yayınladıkları makale yapay sinir ağları konusundaki ilk makale sayılmaktadır. Bu makalede sinirlerin giriş faaliyet seviyesi, belirli bir eşik değerine eriştiğinde aktif hale geçen açık/kapalı anahtar gibi davrandıklarını ve mantık fonksiyonlarını hesaplamak için çeşitli şekillerde bir araya getirilebileceklerini göstermiştir. 1949'da nöropsikolog Hebb yayınladığı makalede beynin öğrenme yeteneğini bir modelle açıklamıştır. "Hebbian öğrenme" kuralı denilen bu kural günümüzde de birçok öğrenme kuralının temelini oluşturmaktadır. 1954'te M. Minsky yapay sinir ağları konusunda doktora yapmış ve 1960'lı yıllarda yapay sinir ağlarına ilgi büyük ölçüde artmıştır. Bu yıllarda F. Rosenblatt, McCulloch ve Pitts'in eşik değeri yaklaşımını kullanarak tecrübeye dayanan, öğrenebilen eleman ağlarını meydana getirmiştir. Yine bu yıllarda S. Grossberg, verbal öğrenmede deney sonuçlarıyla ifade edilen ağların diferansiyel denklemlerini kurmuş; daha sonra gerçek biyolojik sinir ağlarını ifade eden genel denklem setini çıkarmış ve yaptığı araştırmaların sonunda "Adaptif Rezonans Teorisi"ni geliştirmiştir. 1969 yılında M. Minsky ve S. Papert yapay sinir ağlarındaki sınırlamaları inceledikleri "perceptrons" adlı kitabı yayınlamışlardır. Bu kitapta tek katmanlı ağların "ayrıcılık veya" işlemini gerçeklemek gibi basit sorunları çözemeyecekleri ispatlanmıştır.

Yapay sinir ağlarındaki büyük gelişmeler 1980'li yıllarda gerçekleşmiştir. 1980'lerin başında J. Hopfield, gelişmeyle birlikte rasgele bulunan etkenlerin probleme karıştığını ve her çözüm yolunda problemin başlangıç halinde bulunduğu işaret etmiş, bu nedenle her hesaplamanın doğru çözüm yolu için sürekli yenilenen bir mekanizmaya ihtiyaç olduğunu belirterek bu iş için geliştirdiği stratejiyi yapay sinir ağlarında kullanmıştır. 1986 yılında

D. Rummelhart, G. Hinton ve R. Williams geriye yayının öğrenme kuralıyla çok tabakalı ağ sistemlerinin bir çok problemi çözmek için eğitilebileceğini göstermiştir. Son yıllarda bilgisayar teknolojisindeki büyük gelişmelerden dolayı, yapay sinir ağlarının yazılım ve donanım uygulamaları hızla devam etmektedir [9].

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


2. 2. Sinir Ağlarının Biyolojik Yapısı

Canlıları dış ortamdaki değişikliklere karşı kendi iç ortamını belirli sınırlar içerisinde koruyan sinir sistemi, sinir hücrelerinden meydana gelmiş bir yapıdır. Sinirler vücuttaki diğer hücrelerle birçok ortak özelliklere sahiptir, fakat ilave olarak elektrokimyasal işaretleri algılama, işleme ve iletme özellikleri de vardır. Canlı bir sinir sisteminin temelini oluşturan bir sinir hücresi Şekil 2.1’de görülmektedir.

Bir sinir hücresi, bir hücre gövdesi ile dendrit ve akson adı verilen uzantılardan meydana gelir. Sinir hücresi, dendrit adı verilen bir kısım uzantılarla diğer sinir hücrelerinden aldığı işaretleri hücre gövdesine taşır ve hücre gövdesinde toplanan bu işaretler değerlendirilerek bir çıkış işareti üretilir ve bu işaretler akson adı verilen uzantılar vasıtasıyla diğer sinir hücresine gönderilir. Bir sinir hücresinde birçok dendrit olmasına karşın tek bir akson vardır. Yani bir sinir hücresinde birçok giriş bulunmasına rağmen tek bir çıkış vardır.

İki sinir hücresi arasında birinin dendriti ile diğerinin aksonu arasında bir bağlantı vardır ve bu bağlantı yerine sinaps adı verilir. Bu bağlantı yerinde sinirler birbirine bağlı değildir. İki hücre arasında küçük bir bağlantı bulunmamasına rağmen iki sinir hücresi darbeleri iletme için birbirine yeterince yakındır.

Sinir hücrelerinin en büyük özelliği ise, sinir hücresinin çevreden gelen işaretlere ya cevap vermesi ya da vermemesidir. Eğer sinir hücresine gelen işaret, eşik değerini aşarsa hücre tarafından kabul edilir ve cevaplandırılır, eşik değerini aşmıyorsa yok kabul edilerek hiçbir cevap üretilmez.



Şekil 2.1. Biyolojik Sinir Hücresi

Biyolojik beynin en önemli özelliklerinden birisi de, öğrenme olayıdır. İnsanlar ve hayvanlar, sürekli olarak içerisinde bulundukları çevre ile ilişki neticesinde bir öğrenme işlemi içerisindeyler. Öğrenilen her yeni bilgi, beynin fonksiyonlarını hemen etkileyerek, yapılan davranışlara yansır. Yapay sinir ağlarının gerçekleştirilmesinde bu özellik esas teşkil eder.

Yapay sinir ağları (YSA) kavramı beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya atılmış ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin, ya da literatürdeki ismiyle nöronların matematiksel olarak modellenmesi üzerinde yoğunlaşmıştır [1].

2.3. Yapay Sinir Ağının Tanımı

Yapay sinir ağları, insan beyninin çalışma mekanizmasını taklit ederek geliştirilen ve biyolojik olarak insan beyninin yaptığı temel işlemleri belirli bir yazılımla gerçekleştirmeyi amaçlayan bir mantıksal programlama tekniğidir. Bilgisayar ortamında, beynin yaptığı işlemleri yapabilen, karar veren, sonuç çıkaran, yetersiz veri durumunda var olan mevcut bilgiden yola çıkarak sonuca ulaşan, sürekli olarak veri girişini kabul eden, öğrenen, hatırlayan bir algoritmadır [10].

Yapay sinir ağları, insanlar tarafından gerçekleştirilmiş örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üretileceğini belirleyebilen bilgisayar sistemlerdir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde,

- Öğrenme
- İlişkilendirme
- Sınıflandırma
- Genelleme

- Özellik belirleme
- Optimizasyon

gibi konularda başarılı bir şekilde uygulanmaktadır. Örneklerden elde ettikleri bilgiler ile kendi deneyimlerini oluşturur ve daha sonra, benzer konularda benzer kararları verirler.

Yapay sinir ağları, yapay sinir hücrelerinin katmanlar şeklinde bağlanmasıyla oluşturulan veri tabanlı sistemler olup insan beyninin öğrenme ve değişik koşullar altında çok hızlı karar verebilme gibi yeteneklerinin, basitleştirilmiş modeller yardımıyla karmaşık problemlerin çözülmesinde kullanılmasını amaçlamaktadır [11].

Teknik olarak da, bir yapay sinir ağının en temel görevi, kendisine gösterilen bir girdi setine karşılık gelebilecek bir çıktı seti belirlemektir. Bunun yapılabilmesi için ağ, ilgili olayın örnekleri ile eğitilerek genelleme yapabilecek yeteneğe kavuşturulur. Bu genelleme ile benzer olaylara karşılık gelen çıktı setleri belirlenir [6].

İnsan beyninin ne olduğu ve nasıl çalıştığı henüz kesinlik derecesinde keşfedilmiş sayılmaz. Günümüzde her ne kadar karmaşık matematiksel hesaplamaları ve hafıza işlemlerini eldeki mevcut bilgisayarlarla hızlı ve doğru yapmak mümkün ise de, aynı bilgisayarlarla beynin birçok basit fonksiyonunu (görmek, duymak, koklamak, ...vs.) yerine getirmek ya mümkün olmamakta veya oldukça zor olmaktadır. Aynı şekilde biyolojik beyin, tecrübe ile öğrenme ve bilgiyi kendi kendine yorumlama, hatta eksik bilgilerden sonuçlar çıkartma kabiliyetine sahiptir. Bu, daha çok biyolojik sistemlerin, hücreler üzerinde dağıtılmış bilgiyi paralel olarak işleme özelliklerinden kaynaklanır. Hücreler birbirine bağlı ve paralel çalıştıklarından bazılarının işlevini yitirmesi halinde, diğerleri çalıştığı için sinir sistemi, fonksiyonunu tamamen yitirmez. İşte yapay sinir ağları, bu özellikleri bünyesinde toplayacak şekilde geliştirilmektedir.

Yapay sinir ağları, biyolojik olmayan yapı taşlarının düzgün bir tasarımla birbirlerine yoğun olarak bağlanmalarından oluşmaktadırlar. Sinir sisteminin modellenmesi için yapılan çalışmalar sonucu oluşturulan yapay sinir ağları, biyolojik sinir sisteminin üstünlüklerine de sahiptir. Bu üstünlükleri şu şekillerde özetleyebilmek mümkündür. Birinci üstünlük YSA'nın paralellik özelliğidir. YSA modelinde her eleman kendi kendinin işlemcisi olabilmektedir. Aynı katmanlar arasında zaman bağımlılığı yoktur, tamamıyla eşzamanlı olarak çalışabilirler. Bu özelliği nedeniyle YSA, hız konusunda oldukça büyük üstünlük sağlamaktadır. İkinci üstünlüğü ise, YSA'nın öğrenebilme özelliğinin bulunmasıdır. İnsan sinir sisteminin, problemleri çözebilmek için öğrenme özelliği olduğu gibi, YSA'nın da bu özelliği mevcut bulunmaktadır. Üçüncü üstünlüğü ise, paralel çalışan YSA'nın karışık işlevler gerektirmemesi, basit işlemleri içermesidir. YSA'nın bir başka üstünlüğü de ayrı ayrı elemanlarda meydana gelen hasarın, başarımda ciddi bir düşüşe yol açmamasıdır. Hâlbuki bilgisayarın herhangi bir işlem elemanını yerinden almak onu etkisiz bir makineye dönüştürmektedir [12].

2.4. Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağları makine öğrenmesi gerçekleştirirler: Yapay sinir ağlarının temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.

Programları çalışma stili bilinen programlama yöntemlerine benzememektedirler: Geleneksel programlama ve yapay zekâ yöntemlerinin uygulandığı bilgi işleme yöntemlerinden tamamen farklı bir bilgi işleme yöntemi vardır.

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

Yapay sinir ağları örnekleri kullanarak öğrenirler: Yapay sinir ağlarının olayları öğrenebilmesi için o olay ile ilgili örneklerin belirlenmesi gerekmektedir. Örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneğe kavuşturulurlar (adaptif öğrenme). Örnek bulunamıyorsa veya yok ise yapay sinir ağının eğitilmesi mümkün değildir. Örnekler ise gerçekleşmiş olan olaylardır. Mesela bir doktor hastasına bazı sorular sorar ve aldığı cevaplara göre teşhis ederek ilaç yazar. Sorulan sorular ve verilen cevaplar ile konulan teşhis bir örnek olarak nitelendirilir. Bir doktorun belirli bir zaman içinde hastaları ile yaptığı görüşmeler ve koyduğu teşhisler not edilerek örnek olarak alınırsa yapay sinir ağı benzer hastalıklara benzer teşhisi koyabilir. Elde edilen örneklerin olayı tamamı ile gösterebilmesi çok önemlidir. Ağa olay bütün yönleri ile gösterilemez ve ilgili örnekler sunulmaz ise başarılı sonuçlar elde edilemez. Bu ağın sorunlu olduğundan değil olayın ağa iyi gösterilemediğindendir. O nedenle örneklerin oluşturulması ve toplanması yapay sinir ağı biliminde özel bir öneme sahiptir.

Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir: Yapay sinir ağlarının eğitilmesi demek, mevcut örneklerin tek tek ağa gösterilmesi ve ağın kendi mekanizmalarını çalıştırarak örnekteki olaylar arasındaki ilişkileri belirlemesidir. Her ağı eğitmek için elde bulunan örnekler iki ayrı sete bölünürler. Birincisi ağı eğitmek için (eğitim seti) diğeri ise ağın performansını sınamak için (test seti) kullanılır. Her ağ önce eğitim seti ile eğitilir. Ağ bütün örneklerle doğru cevaplar vermeye başlayınca eğitim işi tamamlanmış kabul edilir. Daha sonra ağın hiç görmediği test setindeki örnekler ağa gösterilerek ağın verdiği cevaplara bakılır. Eğer ağ hiç görmediği örneklerle kabul edilebilir bir doğrulukta cevap veriyor ise o zaman ağın performansı iyi kabul edilir ve ağ kullanıma alınır. Eğer ağın performansı yetersiz olursa o zaman yeniden eğitmek

veya yeni örnekler ile eğitmek gibi bir çözüme gidilir. Bu işlem ağın performansı kabul edilebilir bir düzeye gelinceye kadar devam eder.

Görülmemiş örnekler hakkında bilgi üretebilirler: Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.

Algılamaya yönelik olaylarda kullanılabilirler: Ağlar daha çok algılamaya yönelik bilgileri işlemede kullanılırlar. Bu konuda başarılı oldukları yapılan uygulamalarda görülmektedir. Bilgiye dayalı çözümlerde uzman sistemler kullanılmaktadır. Bazı durumlarda yapay sinir ağı ve uzman sistemleri birleştirmek daha başarılı sistemler oluşturmaya neden olmaktadır.

Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler: Genel olarak ağların çoğunun amacı kendisine örnekler halinde verilen örüntülerin kendisi veya diğerleri ile ilişkilendirilmesidir. Diğer bir amaç ise sınıflandırma yapmaktır. Verilen örneklerin kümelenendirilmesi ve belirli sınıflara ayrıştırılarak daha sonra gelen bir örneğin hangi sınıfa gireceğine karar vermesi hedeflenmektedir.

Örüntü tamamlama gerçekleştirebilirler: Bazı durumlarda ağa eksik bilgileri içeren bir örüntü veya bir şekil verilir. Ağın bu eksik bilgileri bulması istenir. Örneğin yırtık bir resmin kime ait olduğunu belirlemesi ve tam resmi vermesi gibi bir sorumluluk ağdan istenebilmektedir. Bu tür olaylarda yapay sinir ağlarının çok etkin çözümler ürettiği bilinmektedir.

Kendi kendini organize etme ve öğrenebilme yetenekleri vardır: Yapay sinir ağlarının örnekler ile kendisine gösterilen yeni durumlara adapte olması ve sürekli yeni olayları öğrenebilmesi mümkündür.

Eksik bilgi ile çalışabilmektedirler: Yapay sinir ağları kendileri eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilirler. Eksik bilgiler ile de çalışmaya devam ederler. Hâlbuki geleneksel sistemler bilgi eksik olunca çalışmazlar. Burada bir noktaya dikkatleri çekmekte fayda vardır. Yapay sinir ağlarının eksik bilgiler ile çalışması performanslarının düşeceği anlamına gelmez. Performansın düşmesi eksik olan bilginin önemine bağlıdır. Hangi bilginin önemli olduğunu ağ kendisi eğitim sırasında öğrenmektedir. Kullanıcıların bu konuda bir fikri yoktur. Ağın performansı düşük olunca, kayıp olan bilginin önemli olduğu kararına varılır. Eğer ağın performansı düşmez ise eksik olan bilginin önemli olmadığı anlaşılır.

Hata toleransına sahiptirler: Yapay sinir ağlarının eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. Ağın bazı hücrelerinin bozulması ve çalışamaz duruma düşmesi halinde ağ çalışmaya devam eder. Ağın bozuk olan hücrelerinin sorumluluklarının önemine göre ağın performansında düşmeler görülebilir. Hangi hücrelerin

sorumluluklarının önemli olduğuna da yine ağ eğitim esnasında kendisi karar verir. Bunu kullanıcı bilmemektedir. Ağın bilgisayarın yorumlanamamasının sebebi de budur.

Belirsiz, tam olmayan bilgileri işleyebilmektedirler: Yapay sinir ağlarının belirsiz bilgileri işleyebilme yetenekleri vardır. Olayları öğrendikten sonra belirsizlikler altında ağlar öğrendikleri olaylar ile ilgili ilişkileri kurarak kararlar verebilirler.

Dereceli bozulma gösterirler: Yapay sinir ağlarının hatalara karşı toleranslı olmaları bozulmalarının da dereceli (göreceli) olmasına neden olmaktadır. Bir ağ (Network) zaman içerisinde yavaş yavaş ve zarif bir şekilde bozulur. Bu eksik olan bilgiden veya hücrelerin bozulmasından kaynaklanır. Ağlar, herhangi bir problem ortaya çıktığında hemen anında bozulmazlar.

Dağıtık belleğe sahiptirler: Yapay sinir ağlarında bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir. Tek bir bağlantının bir anlamı yoktur. Daha önce belirtildiği gibi ağın bilgilerinin açıklanamamasının sebeplerinden birisi de budur. Bu ağlarda, ağın tamamı öğrendiği olayın bütünü karakterize etmektedir. O nedenle bilgiler ağa dağıtılmış durumdadır. Bu ise dağıtık bir belleğin doğmasına neden olmaktadır.

Sadece nümerik bilgiler ile çalışabilmektedirler: Yapay sinir ağları sadece nümerik bilgiler ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin nümerik gösterime çevrilmeleri gerekmektedir.

Burada açıklanan özellikler dikkatlice incelenirse aslında yapay sinir ağlarının bilgisayar bilimine oldukça avantajlı katkılarının olduğu görülebilir. Geleneksel bilgisayar yazılım teknolojisi ile çözülemeyen birçok problemin yapay sinir ağları ile çözülebileceği görülebilir. Mesela yapay sinir ağları, eksik, normal olmayan, belirsiz bilgileri işleyebilen en güçlü problem çözme tekniğidir denilse yanlış olmaz. Belirsiz bilgileri işlemeye bulanık önermeler mantığı (Fuzzy Logic) gibi teknikler olsa bile eksik bilgi ile çalışabilen teknikler bulmak çok zordur.

2.5. Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarının yukarıda belirtilen birçok avantajlı özelliklerinin yanı sıra bazı dezavantajları da vardır. Bunları kısaca aşağıdaki gibi özetlemek mümkündür;

Yapay sinir ağlarının donanım bağımlı çalışmaları önemli bir sorun olarak görülebilir. Ağların temel varoluş nedenlerinden biriside paralel işlemciler üzerinde çalışabilmeleridir. Ağların özellikle, gerçek zamanlı bilgi işleyebilmeleri paralel çalışabilen işlemcilerin varlığına bağlıdır. Günümüzdeki makinelerin çoğu seri şekilde çalışabilmekte ve aynı zamanda sadece

tek bir bilgiyi işleyebilmektedir. Paralel işlemleri seri makinelerde yapmak ise zaman kaybına yol açmaktadır. Bunun yanı sıra bir ağı nasıl oluşturulması gerektiğini belirleyecek kuralların olmaması da başka bir dezavantajdır. Her problem farklı sayıda işlemci gerektirebilir. Bazı problemleri çözebilmek için gerekli olan paralel işlemcilerin tamamını bir arada (paralel olarak) çalıştırmak mümkün olmayabilir.

Probleme uygun ağ yapısının belirlenmesi genellikle deneme yanılma yolu ile yapılmaktadır bu ise önemli bir problemdir. Çünkü eğer problem için uygun bir ağ oluşturulmaz ise çözümü olan bir problemin çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusu olabilir. Bu aynı zamanda bulunan çözümün en iyi çözüm olduğunu da garanti etmez. Yani yapay sinir ağları kabul edilebilir çözümler üretebilir. Optimum (en iyi) çözümü garanti etmez.

Bazı ağlarda ağın parametre değerlerinin (mesela öğrenme katsayısı, her katmanda olması gereken proses elemanı (yapay hücrelerin) sayısı, katman sayısı vb.) belirlenmesinde de bir kural olmaması diğer bir problemdir. Bu, iyi çözümler bulmayı zor durumda bırakan bir etken olarak görülebilir. Bu parametrelerin belirlenmesi de kullanıcının tecrübesine bağlıdır. Her problem için ayrı faktörleri dikkate almayı gerektirmektedir. Bu parametre değerleri için belirli standartların oluşturulması çok zor olduğundan her problem için ayrı ayrı değerlendirmeler yapılması gerekmektedir. Bu da önemli bir dezavantaj olarak görülebilir.

Ağın öğreneceği problemin ağa gösterimi de çok önemli bir problemdir. Yapay sinir ağları yukarıda belirtildiği gibi sadece nümerik bilgiler ile çalışmaktadırlar. Problemin nümerik gösterime dönüştürülmesi lazımdır. Bu ise kullanıcının becerisine bağlıdır. Uygun bir gösterim mekanizmasının kurulamamış olması problemin çözümünü engelleyebilir veya düşük performanslı bir öğrenme (çözüm) elde edilebilir. Problemin nümerik gösterimi mümkün olsa bile bunun ağa gösteriliş şekli problemin başarılı bir şekilde çözülmesini yakından etkiler. Örneğin bir olay hem ayrık (binary-ikili) hem de sürekli değerler ile gösterilebilir. Bunun hangisinin daha başarılı bir öğrenme gerçekleştirileceği ise bilinmemektedir. Bu konuda, kullanıcının tecrübesi de yeterli olmayabilir. Bu günümüzde birçok olayın yapay sinir ağları ile çözülememesinin en önemli nedenlerinden birisidir [6].

2.6. Yapay Sinir Ağlarında Öğrenme ve Öğrenme Yöntemleri

Yapay sinir ağları insanlar gibi örneklerle eğitilirler. Yapay sinir ağlarının öğrenmesi bir çocuğun öğrenmesi gibidir. Sıcak bir nesneye dokunmaması gerektiğini deneyerek öğrenen çocuklar zamanla daha az sıcak olan bir cisme dokunabilme cesaretini gösterirler ve sıcak süt ile dolu bardağı elleriyle tutarlar. Yani çocuk sıcaklık bilgisini öğrenmiş olmaktadır. Yapay

nöronlar da benzer olarak; mevcut örnek kümesi üzerinde girdi ve çıktı arasındaki bağıntıyı ağırlıkların değiştirilmesiyle öğrenirler [13].

Yapay sinir ağlarının öğrenme sürecinde, dış ortamdan gözle veya vücudun diğer organlarıyla uyarıların alınması gibi dış ortamdan girişler alınır, bu girişlerin beyin merkezine iletilerek burada değerlendirilip tepki verilmesi gibi yapay sinir ağında da aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı üretilir. Bu çıkış yine tecrübeye verilen çıkışla karşılaştırılarak hata bulunur. Çeşitli öğrenme algoritmalarıyla hata azaltılıp gerçek çıkışa yaklaşılmaya çalışılır. Bu çalışma süresince yenilenen yapay sinir ağının ağırlıklarıdır. Ağırlıklar her bir çevrimde yenilerek amaca ulaşmaya çalışılır. Amaca ulaşmanın veya yaklaşmanın ölçüsü de yine dışarıdan verilen bir değerdir. Eğer yapay sinir ağları verilen giriş-çıkış çiftleriyle amaca ulaşmış ise ağırlık değerleri saklanır. Ağırlıkların sürekli yenilenip istenilen sonuca ulaşana kadar geçen zamana öğrenme adı verilir.

Daha önce belirtildiği gibi bir yapay sinir ağının sahip olduğu bilgi, işlem elemanları arasındaki bağlantı hatları üzerinde saklanır ve ağırlıklar vasıtası ile gösterilir. Ağ, olaylar hakkında giriş ve çıkışlar arasındaki ilişkiyi, elde bulunan mevcut örneklerden genellemeler yaparak öğrenir ve bu genelleme ile yeni oluşan ve ortaya çıkan daha önce hiç görülmemiş olaylar hakkında karar verir. Yani ağa, bir örnek olay gösterildiğinde, giriş katmanından alınıp ara katmanlarda işlenerek, ağın o olay hakkında ürettiği sonuç, çıkış katmanına sunulur. Bu bilgiyi işleme, ağın sahip olduğu tecrübeye göre, bilginin ara katmanlarda çağrıştırılması ile gerçekleştirilir. Bu çağrıştırma olayı modelden modele değişmektedir. Mesela, ara katmanlardaki işlem elemanları sahip oldukları bağlantılar ile kendi kararlarını üretir ve çıkış katmanındaki işlem elemanlarına gönderirler. Çıkış katmanındaki işlem elemanları da, yine ilgili ağırlıkları kullanarak ağın en son kararını oluştururlar. Bu ağırlıklar, tıpkı ilgili olayın belirli özelliklerini hafızada saklayan elemanlar gibi düşünülebilirler. Bilgi işleme ise (örüntü tanıma gibi), bir olay gösterildiğinde hafızadan ilgili özellikleri çağırarak ve bunlar ile ilgili girişleri birlikte analiz ederek karar vermek şeklinde yorumlanabilir.

Yapay sinir ağının öğrenme işlemini gerçekleştirebilmesi için, sahip olduğu bütün ağırlıkların, ilgili problemde öğrenilmesi istenen özellikleri genelleştirecek şekilde doğru değerlere sahip olması gerekir. Bu doğruluk ne kadar artarsa ağın öğrenme işlemi o kadar iyi olur. Doğru ağırlık değerleri, bir öğrenme kuralına göre tespit edilirler. Çoğunlukla bağlantılara başlangıç değerleri olarak rasgele ağırlıklar atanır ve bu ağırlıklar eldeki örnekler incelendikçe bir kurala göre değiştirilerek doğru ağırlık değerleri bulunmaya çalışılır. Kısaca belirtmek gerekirse öğrenme kuralları, bir işlem elemanının örnekleri gördükçe kazandığı tecrübeye göre, ilgili bağlantı ağırlıklarını nasıl değiştireceğini belirleyen algoritmalarlardır. Öğrenme yöntemleri temelde üç grupta toplanır [14].

2.6.1. Eđiticiili ğrenme

Bu yöntemde, dışardan bir eğiticiinin sinir ağına müdahalesi söz konusudur. Eğitici, sinir ağının ilgili giriş için üretmesi gereken sonucu sinir ağı sistemine verir. Yani yapay sinir ağına giriş/çıkış ikilisinden oluşan örnekler sunulur. Bu ikili, ağın öğrenmesi gereken özellikleri temsil eder. Ağ giriş kısmını alır ve o anki bağlantı ağırlıklarının temsil ettiđi bilgi ile bir çıkış oluşturur. Bu çıkış, olması gereken çıktı ile mukayese edilir ve aradaki hata tekrar ağa aktarılarak ağırlıklar bu hatayı azaltacak şekilde deđiştirilirler.

2.6.2. Eđiticisiz ğrenme

Bu yöntemde hiç bir eğiticiye ihtiyaç yoktur. Bu nedenle çođu zaman buna kendi kendine organize olma (self-organized learning) da denilmektedir. Ağ, kendine gösterilen örnekleri alır ve belli bir kritere göre sınıflandırır. Bu kriter önceden bilinmeyebilir. Ağ, kendi öğrenme kriterlerini kendisi oluşturmaktadır.

2.6.3. Takviyeli ğrenme

Bu yöntemde de yine eğiticiye ihtiyaç vardır. Yukarıdaki yöntemden farkı ise, bu durumda eğiticiinin, ağın üretmesi gereken sonuç yerine, onun ürettiđi sonucun sadece dođru veya yanlış olduđunu söylemesidir. Bu ise ağa bir takviye sinyalinin gönderilmesi ile gerçekleştirilir. Bu yöntem, ilgili örnek için beklenen çıktının oluşturulamadıđı durumlarda çok faydalıdır.

2.7. Yapay Sinir Ağlarında ğrenme Kuralları

Öğrenme sistemlerinde kullanılan deđişik öğrenme kuralları vardır. Yapay sinir ağlarında kullanılan bu öğrenme kurallarının çođu Hebb kuralına dayanmaktadır.

2.7.1. Hebb Kuralı

Bilinen en eski öğrenme kuralıdır. Diđer öğrenme kurallarının temelini oluşturmaktadır. 1949 yılında geliştirilen bu kurala göre, bir hücre (yapay sinir ağı elemanı) diđer bir hücreden bilgi alırsa ve her iki hücrede aktif ise (matematik olarak aynı işareti taşıyorsa) her iki hücrenin arasındaki bağlantı kuvvetlendirilmelidir. Diđer bir deyişle bu kural şu şekilde özetlenebilir. Bir

hücre kendisi aktif ise bağlı olduğu hücreyi aktif yapmaya pasif ise pasif yapmaya çalışmaktadır. Diğer öğrenme kurallarının çoğu bu felsefeyi temel alarak geliştirilmiştir.

2.7.2. Hopfield Kuralı

Bu kural Hebb kuralına benzemektedir. Yapay sinir ağı elemanlarının bağlantılarının ne kadar kuvvetlendirilmesi veya zayıflatılması gerektiği belirlenir. Eğer beklenen çıktı ve girdiler ikisi de aktif/pasif ise öğrenme katsayısı kadar ağırlık değerleri kuvvetlendir/zayıflat denmektedir. Yani, ağırlıkların kuvvetlendirilmesi veya zayıflatılması öğrenme katsayısı yardımı ile gerçekleştirilmektedir. Öğrenme katsayısı genel olarak 0–1 arasında kullanıcı tarafından atanan sabit ve pozitif bir değerdir.

2.7.3. Kohonen Kuralı


Bu kurala göre, ağı elemanları (hücreleri) ağırlıklarını değiştirmek için birbirleri ile yarışır. En büyük çıktıyı üreten hücre kazanan hücre olmakta ve bağlantı ağırlıkları değiştirilmektedir. Bu, o hücrenin yakınındaki hücelere karşı daha kuvvetli hale gelmesi demektir. Hem kazanan elemanların hem de komşuları sayılan elemanların (hücrelerin) ağırlıklarını değiştirmesine izin verilmektedir.

2.7.4. Delta Kuralı

Bu kural Hebb kuralının biraz daha geliştirilmiş şeklidir. Bu kurala göre beklenen çıktı ile gerçekleşen çıktı arasındaki farklılığı azaltmak için yapay sinir ağının elemanlarının bağlantılarının ağırlık değerlerinin sürekli değiştirilmesi ilkesine dayanarak geliştirilmiştir. Ağı ürettiği çıktı ile üretilmesi gereken (beklenen) çıktı arasındaki hatanın karelerinin ortalamasını azaltmak hedeflenmektedir.

2.8. Yapay Sinir Hücresi

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri mühendislik biliminde *proses elemanları* olarak da adlandırılmaktadır. Şekil 2.2’de görüldüğü gibi her proses elemanının 5 temel elemanı vardır. Bunlar:



Şekil 2.2. Yapay Sinir Hücresinin Modeli.

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

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

- **Toplama Fonksiyonu:** Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağız gelen net girdi bulunmuş olur. Bu şu şekilde formülize edilmektedir.

$$NET = \sum_i^n G_i A_i \quad (2.1)$$

burada G girdileri, A ağırlıkları, n ise bir hücreye gelen toplam girdi (proses elemanı) sayısını göstermektedir. Yalnız yapay sinir ağlarında daima bu formülün kullanılması şart değildir. Uygulanan yapay sinir ağı modellerinden bazıları kullanılacak toplama fonksiyonunu belirleyebilmektedir. Literatürde yapılan araştırmalarda toplama fonksiyonu olarak değişik formüllerin kullanıldığı görülmektedir. Tablo 2.1'de değişik toplama fonksiyonlarına örnekler verilmektedir. Görüldüğü gibi 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. Bir yapay sinir ağında bulunan proses elemanlarının tamamının aynı toplama fonksiyonuna sahip olmaları gerekmez. Her proses elemanı bağımsız olarak farklı bir toplama fonksiyonuna sahip olabilecekleri gibi hepsi aynı proses elemanına sahip olabilir. Hatta ağın bazı proses elemanları grup halinde aynı toplama fonksiyonuna sahip olabilir. Diğerleri ise farklı fonksiyonlar kullanabilirler. Bu tamamen tasarımcının kendi öngörüsüne dayanarak verdiği karara bağlıdır.

Tablo 2.1. Toplama Fonksiyonu Örnekleri

Net Giriş	Açıklama
<i>Çarpım</i> $Net\ Girdi = \sum_i G_i A_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.
<i>Maksimum</i> $Net\ Girdi = \max(G_i A_i), i = 1, \dots, n$	n adet girdi içinden ağırlıklar ile çarpıldıktan sonra en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
<i>Minimum</i> $Net\ Girdi = \min(G_i A_i), i = 1, \dots, n$	n adet girdi içinden ağırlıklar ile çarpıldıktan sonra en küçüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
<i>Çoğunluk</i> $Net\ Girdi = \sum_i \text{sgn}(G_i A_i)$	n adet girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
<i>Kümülatif Toplam</i> $Net\ Girdi = Net(eski) + \sum_i^n G_i A_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

- **Aktivasyon Fonksiyonu:** Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da çıktıyı hesaplamak için değişik formüller kullanılmaktadır. Bazı modeller (mesela çok katmanlı algılayıcı) bu fonksiyonun türevinin alınabilir bir fonksiyon olmasını şart koşturmaktadır. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da ağın proses elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Bazı elemanlar aynı fonksiyonu diğerleri farklı fonksiyonları kullanabilirler. Bir problem için en uygun fonksiyonda yine tasarımcının denemeleri sonucunda belirleyebileceği bir durumdur. Uygun fonksiyonu gösteren bir formül bulunmuş değildir.

Günümüzde en yaygın olarak kullanılan **çok katmanlı algılayıcı** modelinde genel olarak aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmaktadır. Bu fonksiyon şu formül ile gösterilmektedir.

$$F(NE T) = \frac{1}{1 + e^{-NE T}} \quad (2.2)$$


Burada NET, proses elemanına gelen NET girdi değerini göstermektedir. Bu değer toplama fonksiyonu kullanılarak belirlenmektedir.

Aktivasyon fonksiyonu olarak kullanılacak olan diğer fonksiyonlara örnekler ise Tablo 2.2'de verilmiştir:

Tablo 2.2. Aktivasyon Fonksiyonu Örnekleri

Aktivasyon Fonksiyonu	Açıklama
Lineer Fonksiyon $F(NE T) = NE T$	Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir.
Step Fonksiyonu $F(NE T) = \begin{cases} 1 & \text{eğer } NE T > \text{eşik değeri} \\ 0 & \text{eğer } NE T \leq \text{eşik değeri} \end{cases}$	Gelen NET girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerlerini alır.
Sinüs Fonksiyonu $F(NE T) = \sin(NE T)$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.
Eşik Değer Fonksiyonu $F(NE T) = \begin{cases} 0 & \text{eğer } NE T \leq 0 \\ NE T & \text{eğer } 0 < NE T < 1 \\ 1 & \text{eğer } NE T \geq 1 \end{cases}$	Gelen bilgilerini 0 veya 1'den büyük veya küçük olmasına göre bir değerler alır. 0 ve 1 arasında değerler alabilir. Bunların dışında değerler alamaz.
Hiperbolik Tanjant Fonksiyonu $F(NE T) = (e^{NE T} - e^{-NE T}) / (e^{NE T} + e^{-NE T})$	Gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.

En çok kullanılan dört tane aktivasyon fonksiyonu vardır. Bunlar sigmoid, lineer, hiperbolik tangant ve step fonksiyonudur. Şekil 2.3'de bu fonksiyonlar gösterilmiştir.



Şekil 2.3. Aktivasyon Fonksiyonları.

• **Hücrenin Çıktısı:** Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dış dünyaya veya başka bir hücreye gönderilir. Hücre kendi çıktısını kendisine girdi olarak da gönderebilir [6].

2.9. Yapay Sinir Ağlarının Yapıları ve Çeşitleri

Yapay sinir ağlarının görevlerini gerçekleştirmede, sahip oldukları fiziksel yapının da önemi vardır. Bugün 50'ye yakın farklı yapılanma görülmekte ve bu sayı her geçen gün artmaktadır [15]. Farklı yapılaşma, işlem elemanlarının birbirleri ile olan bağlantılarından ve uygulanan öğrenme kuralından kaynaklanmaktadır. İşlem elemanları ya tamamen birbirleri ile bağlantılı veya yerel olarak gruplar halinde bağlantılı olabildikleri gibi değişik şekilde de birbirleri ile bağlanabilmektedirler. Bilgi akışı bu bağlantılar üzerinden tek yönlü olduğu gibi, çift yönlü de olabilir. Bir grup işlem elemanı bir araya gelerek bir katman oluştururlar. Genel itibarıyla yapay sinir ağlarında 3 tür katman bulunur. Sinir ağının dış dünya ile bağlantısını kuran girdi katmanı, gelen bilgileri işleme kabiliyetine sahip ara katmanlar ve sinir ağının kararlarını dış dünyaya aktaran bir çıkış katmanı. Giriş katmanında çoğu zaman bilgi işleme söz konusu olmaz. Bu katmandaki işlem elemanları aldıkları bilgiyi herhangi bir değişikliğe uğratmadan ara katmandaki işlem elemanlarına aktarırlar. Burada sözü edilen bilgi, sinir ağının


işlem elemanları arasındaki bağlantı hatları üzerinde bulunan ağırlıklarla ifade edilir. Dolayısıyla bilgi, bütün ağıya dağıtılmış demektir. Bu bilgiler, yapay sinir ağının belleğidir veya diğer bir deyişle yapay sinir ağları eğitildikten sonra kullanılacağı sistem için bir veri tabanıdır.

Araştırmacılar birçok farklı yapay sinir ağ modelleri yapmışlar ve bunları eğitmek için birçok algoritma geliştirmişlerdir. Bu ağ modellerinin birçoğu biyolojik sinirlerden esinlenerek veya en azından biyolojik olarak geçerli kabul edilmiştir. Bu modellerin her biri belli uygulama alanlarında başarılı olmuşlardır.

2.9.1. Geri Yayılım Ağı

Geri yayılım ağı, 1970'lerin başında geliştirilmiş, en popüler, en etkili ve karmaşık, tanımlanamamış problemlere doğrusal olmayan çözümler getirebilen bir ağ çeşididir.

Geriye yayılma ağı, günümüzde pek çok disiplinde, özellikle mühendislikte en çok kullanılan ağ çeşididir [16]. Bunun en büyük nedeni öğrenme kapasitesinin yüksek ve algoritmasının basit olmasıdır [17]. Bu ağ; hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri yayımlı öğrenme kuralı ağ çıkışındaki mevcut hata düzeyine göre her bir tabakadaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Tipik bir geri yayılım ağının, bir girdi katmanı, bir çıktı katmanı ve en az bir gizli katmanı vardır. Gizli katmanların sayısı için teorik olarak bir sınırlama yoktur. Yapılan bazı çalışmalar, herhangi bir derecede karmaşıklığa sahip problemleri çözmek için en az dört katman (üç gizli katman ve bir çıktı katmanı) bulunması gerektiğini göstermiştir. Şekil 2.4'de bir geri yayılım ağ örneği görülmektedir.



Şekil 2.4. Geri Yayılımlı YSA Mimarisi

Sinir ağlarında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç nöron olacağı bugüne kadar belirlenememiştir, probleme göre değişen bu nitelikler deneme-yanılma yoluyla bulunur.

Geri yayılım ağlarında katman sayısı ve her katmandaki düğüm sayısının seçilmesinde kesin bir yöntem yoktur ve sadece takip edilecek genel kurallar bulunmaktadır.

Kural 1: Girdi verisi ve istenilen çıktı arasındaki ilişkinin karmaşıklığı artınca, gizli katmanlardaki işleme elemanlarının sayısı da artmalıdır.

Kural 2: Eğer ele alınan süreç birçok aşamalara ayrılabilirse, fazla sayıda gizli katman kullanılmalıdır.

Kural 3: Ağda kullanılan eğitim verisinin miktarı, gizli katmanlardaki işleme elemanlarının sayısı için üst bir sınır oluşturmaktadır.

Bir ağ oluşturmak için yukarıdaki belirtilen kurallar uygulandıktan hemen sonra, öğretme süreci başlar. Bu süreçte eğitim verisi ağın giriş katmanına uygulanır ve istenen çıktılar çıkış katmanında karşılaştırılır. Öğrenme süreci esnasında, ağ boyunca bir ileri tarama yapılır ve bir düğümün çıktısı katman katman hesaplanır. En son katmanın çıktısı ve istenilen çıktı arasındaki fark, genellikle aktarım işlevinin türevi tarafından değiştirilen bir önceki katmana geri yayılır ve bağlantı bağıl değerleri Delta kuralını kullanarak ayarlanır.

Geriye yayılma algoritması birbirine bağlı sabit üniteli ve çok katmanlı ağlar için ağırlıkların bulunmasında kullanılan bir algoritmadır. Bu algoritmanın temel prensibi çıkış için hedef değerleri ile ağ çıkışındaki değerler arasındaki hatayı minimize etmeye çalışmaktır [18].

Geri yayılım çok katmanlı ağlarda kullanılan delta kuralı için geliştirilmiştir bir algoritmadır. Bu algoritma çok katlı ağlarda hesap işlerini öğrenmede kullanılabilmektedir. Geri yayılım ağında hatalar, ileri besleme aktarım işlevinin türevi tarafından, ileri besleme mekanizması içinde kullanılan aynı bağlantılar aracılığıyla, geriye doğru yayılmaktadır. Öğrenme işlemi, bu ağda basit çift yönlü hafıza birleştirmeye dayanmaktadır [17].

Hatayı geriye yayma algoritmasının işlem sırası kısaca aşağıdaki gibi verilebilir. Her bir nöronun çıkış değeri hesaplanır.

$$y_i = f\left(\sum_{i=1}^n G_i A_i + b\right) \quad (2.3)$$

İstenen çıktı ile gerçek çıktı karşılaştırılır ve varsa ağın hatası hesaplanır.

$$E = \frac{1}{2} \sum (d_i - y_i)^2 \quad (2.4)$$

Her bir katmandaki ağırlıkların değişimleri belirlenir.

$$\Delta w_i = \eta \cdot \delta_i \cdot y_i \quad (2.5)$$

Bu değerlere göre ağırlıkların güncellemesi yapılır.

$$w_i^{yeni} = w_i^{eski} + \Delta w_i \quad (2.6)$$

Hata verilen uygun değere yaklaştıkça bu adımlar tekrar edilir.

2.9.2. Delta Bar Delta Ağı

Delta bar delta ağı, bir geri yayılım ağı olarak aynı mimariden yararlanmaktadır. Delta bar delta ağının farklılığı, yalnızca kendine has algoritmik öğrenme metodudur. Delta bar delta, Robert Jacobs tarafından, standart ileri beslemeli, geri yayılım ağlarının öğrenme oranını iyileştirmek amacıyla geliştirilmiştir.

Geri yayılım süreci, çok dik bir yokuş yaklaşımı üzerine kurulmuştur. Bu yokuş, her bir düğüme bağlantı bağıl değerlerinin değiştirildiği süreç sırasında ağın tahmin hatasını en aza indirir. Standart öğrenme oranları bir katman temeline uygulanır ve momentum terimi genellikle global olarak atanır. Bazı geri yayılım yaklaşımları, öğrenme oranlarının çok büyük miktarlardaki eğitim dizileri ağıdan geçerken, derece derece azalmalarına imkân sağlar. Bu yöntem birçok uygulamayı çözmekte başarılıdır ancak, sürecin yakınsama oranı bazı pratik problemlerde kullanılmak için çok yavaştır.

Delta bar delta, her bir bağıl değer kendine has kendini uyarlayabilen katsayıya sahip olduğu bir öğrenme metodu kullanmaktadır. Ayrıca, geri yayılım mimarisinin momentum faktörünü kullanmaz. İleri beslemeli çağrışım gibi sebeplerin geriye kalan çalışmaları, normal geri yayılım mimarisine benzerdir. Delta bar delta, yapay sinir ağlarına bir sezgisel yaklaşımdır. Bunun anlamı, eski hata değerlerinin gelecek hesaplanmış, hata değerlerini tahmin etmek için kullanılabileceği demektir. Muhtemel hataları bilmek, sistemin bağıl değerlerini ayarlarken zekâ adımları atmasını sağlar. Ancak, bu sürecin bu ampirik kanıt içerisinde karmaşık olması, her bir bağıl değer, hatanın tamamı üzerinde çok farklı etkilere sahip olduğunu ortaya koymaktadır. Jacobs bundan dolayı, geri yayılım öğrenme kurallarının hatanın tamamı üzerindeki etkilerin bu çeşitliliğini göz önüne alması gerektiğini belirten ortak duyu görüşünü ortaya atmıştır. Diğer bir deyişle, bir ağın her bir bağlantı bağıl değerinin kendi öğrenme oranı olmalıdır.

Bu algoritmaya doğrudan uygulayan kurallar ileri doğru düzdür ve uygulaması kolaydır. Her bir bağlantı bağıl değerinin kendi öğrenme oranı vardır. Bu öğrenme oranları, standart geri yayılım ile birlikte bulunan mevcut hataya bağlı olarak değişir. Bağlantı bağıl değeri değiştiğinde, eğer bölgesel hata çeşitli ardıl zaman adımları için aynı sinyale sahipse, o bağlantının öğrenme oranı doğrusal olarak artırılır. Doğrusal olarak arttırma, öğrenme oranlarının çok büyük ve çok hızlı hale gelmesini önler. Bölgesel hata sinyalleri sık sık değiştirildiğinde, öğrenme oranı geometrik olarak azaltılır. Geometrik olarak azaltma, bağlantı öğrenme oranlarının her zaman pozitif olmasını sağlar. Dahası, bu oranlar, hatadaki değişikliğin büyük olduğu bölgelerde daha hızlı bir şekilde azaltılabilir.

2.9.3. Genişletilmiş Delta Bar Delta Ağı

Minai ve Williams, genişletilmiş delta bar delta algoritmasını Jacobs'un çalışmasının doğal bir uzantısı olarak geliştirmişlerdir. Burada, delta bar delta öğrenme oranı artışına bir üst eksilmesi uygulayıp, momentum unsurunu yeniden buna ekleyip, öğrenme oranı ve momentum katsayısına bir ek koyarak geliştirmişlerdir.


Her bir bağıl değer için öğrenme oranı ve momentum oranı, bunların artış ve azalmalarını kontrol eden ayrı sabitlere sahiptir. Bir kez daha, mevcut hata sinyali, bir artışın mı yoksa bir azalmanın mı uygun olduğunu belirtmek için kullanılır. Azalma ayarlaması, delta bar delta ile aynı şekle sahiptir. Ancak, öğrenme oranı ve momentum oranı artışları, tartılmış eğim unsurların büyüklüğünün üs rakamlara dayanarak düşen işlevleri olmak üzere değiştirilirler. Böylece, büyük artışlar, büyük eğilmelere değil de, küçük yokuş ya da eğilme alanlarına uygulanır. Bu, delta bar delta zıplama problemine kısmi bir çözüm oluşturur.

Bağıl değerlerdeki büyük zıplamaları ve titreşmeleri önlemek amacıyla atılan bir sonraki adım ise, azami sınırların bireysel bağlantı öğrenme oranları ve momentum oranları üzerine yerleştirilir ve düzeltme özelliği olan bir hafıza algoritma içine kurulur. Bunu kullanırken, eğitim verisinin her bir devir sunumundan sonra, biriken hata değerlendirilir. Eğer hata önceki en az hatadan daha az ise, bağıl değerler hafızaya mevcut en iyiler olarak kaydedilir. Bir tolerans değişkeni düzeltme fazını kontrol eder. Özellikle, eğer mevcut hata önceki en az hatadan fazla ise, tolerans değişkeni ile değiştirilerek, bütün bağlantı bağıl değerleri hafızadaki kaydedilmiş en iyiler dizisine tahmini olarak dönerler. Dahası, öğrenme oranları ve momentum oranları, düzeltme sürecini başlatmak için azaltılırlar.

2.9.4. Hopfield Ağı

1982'de John Hopfield tarafından geliştirilen bir ağıdır. Hopfield ağında ikili değerler kullanılır. Hopfield ağı genellikle diğer ağ örneklerini kapsamaktadır.

Şekil 2.5'de temel bir Hopfield ağı görülmektedir. Bu özgün ağ her bir elemanı işleyerek bir ikili sayı biçimi oluşturur. Bu elemanlar girişlerin toplamı ve çıkış sayıları sıfır veya bir olarak hesaplanarak yüklenir.



Şekil 2.5. Bir Hopfield Ağı Örneği

Hopfield ağ topolojisi diğer ağlardan farklıdır. Hopfield ağında, bir giriş süzme katmanı, bir Hopfield katmanı ve bir çıkış katmanı olmak üzere 3 katman kullanılmasına rağmen farklı katmanlar yoktur. Bu ağda her düğüm diğer tüm düğümlere bağlıdır. Ayrıca, bağlantılar çift yönlüdür (bilgi her iki yönde akar) ve simetrikler. Her iki yönde akan veriye uygulanan ve her bağlantı için hesaplanan bir ağırlık değeri vardır.

Hopfield ağı, bir geri yayımlı (BackPropagation) ağı eğitildiği gibi eğitilmez. Bunun yerine, Specht'in olasılıksal sinir ağına benzer ve örnek desen grupları seçilir, ağı ağırlıklarının başlangıç değerlerini saptamak için kullanılır. Bu bir kere yapıldıktan sonra herhangi bir desen ağa sunulur ve bu da giriş desenine en çok benzeyen örnek desenlerden biriyle sonuçlandırılır. Çıkış deseni, birimlerin durumlarına bakılarak ağdan okunabilir.

2.9.5. Boltzman Makinesi

Hinton ve Sejnowski (1983) tarafından oluşturulmuş bir ağıdır. Boltzman makinesi olasılıksal katılımlıdır ve geri besleme bağlantıları Hopfield ağına benzemektedir. Boltzman makinesi Hopfield ağına ilave olarak özgün modelleme tekniğinde benzer işlev ve işlemleri kullanılır. Boltzman makinesi model seviyelerini araştırıp durum uzayında kavramları benzeterek birleştirmiştir.

2.9.6. Hamming Ağı


Hamming ağı Hopfield ağına bir genişletilmesidir. Bu ağ Richard Lippman tarafından 1980'lerin ortalarında geliştirilmiştir. Hamming ağı giriş vektörleri için en az ikili sayı hatasının temel sınıflandırılmasını yerine getirmektedir, burada Hamming tarafından hata aralığı tanımlanmaktadır. Hamming ağına üç seviyesi vardır. Hamming ağı bir giriş seviyesi ile birçok düğümler kullanır. Bir Hamming ağına öğrenmesi Hopfield yöntemlerine benzemektedir. Burada çıkış sabitleri sadece çıkış kategorisine değil aynı zamanda giriş vektörüne de ait olurlar. Tekrar edilen yapı Hopfield seviyesinde bütün bağlantı yüklerinde ortalama bir düzelme sağlar.

Hamming ağı Hopfield ağına göre belirgin üstünlüklere sahiptir. Hamming ağı en az hata sınıfında en uygun durumda çalışır. Hamming ağına giriş bit hataları gelişigüzel ve birbirinden bağımsızdır. Hamming ağı, Hopfield ağına göre daha çabuk ve doğru sonuç verir.

2.9.7. Olasılıksal Sinir Ağları

Olasılıksal sinir ağları 1988'de Donald Specht tarafından geliştirilmiştir. Olasılıksal sinir ağları bir kalıp katman dahilinde dağıtım işlevini geliştirmek için danışmanlı bir eğitim dizisi kullanır. Hatırlama kipinde bu işlevler öğrenilmiş bir kategori veya sınıfın parçası olan bir girdi özelliği vektörünün benzerliğini tahmin etmek için kullanılır. Öğrenilen kalıplar, verilen bir girdi vektörü için en uygun sınıfı belirleyecek her bir kategorinin, aynı zamanda nispi sıklık olarak da adlandırılan, bir ön olasılığı vasıtasıyla birleşebilir veya ölçülebilir. Eğer kategorilerin nispi sıklığı bilinmiyorsa bu durumda tüm kategoriler eşit derecede uygun farz edilir ve kategorinin belirlenmesi yalnızca, girdi özellik vektörünün bir sınıfın dağıtım işlevine yakınlığı temel alınarak gerçekleştirilir.

Şekil 2.6'da bir olasılıksal sinir ağı görülmektedir. Bu ağ üç katmana sahiptir. Bu ağ, sınıflandırılacak nesnelere tanımlaması için ihtiyaç duyulan ayrılabilir değişkenlerin varlığı kadar çok elemana sahip bir girdi katmanı içerir. Eğitim dizisini organize eden bir kalıp katmana sahiptir, örneğin her bir girdi vektörü bireysel bir işleme elemanı tarafından temsil edilir. Ve son olarak, ağ tanınacak sınıflar kadar çok işleme elemanına sahip olan ve toplam katmanı olarak adlandırılan bir çıktı katmanı içerir. Bu katmandaki her bir eleman aynı sınıfla ilişkili kalıp katman dahilinde işlem elemanları yoluyla birleşir ve bu kategoriyi çıktıya hazırlar. Eğer girdiler ağı girmeden daha önce norm haline dönüştürülmezse, girdi vektörünü normlaştırmak için bazen dördüncü bir katman eklenir.



Şekil 2.6. Olasılıksal Sinir Ağı

2.9.8. Uyarlanırlı Rezonans Ağı (ART Ağları)

Uyarlanırlı rezonansa dayanan giriş verilerinin kategorilerini bu ağ oluşturmaktadır. Uyarlanırlı rezonans ağ, 1970'lerin ortalarında Stephen Grossberg tarafından geliştirilmiştir. Bu topoloji biyolojik olarak makuldür ve danışmansız öğretim işlevini kullanır. Bu sistem belirgin giriş verisini analiz eder ve muhtemel özellikleri kontrol eder veya giriş vektörü içindeki karakteristikleri sınıflandırır.

Bu ağ diğer birçok örnek ağlar için bir temel oluşturur. Uyarlanırlı rezonans ağların kalbini giriş ve çıkış katmanlarının arasına yerleştirilmiş işlemci elementlerin karşılıklı birleştirilmiş iki katmanı oluşturmaktadır. Düşük rezonans katmanına bağlı her bir giriş modeli, yüksek katmandan düşük katmana bir sonraki girişi etkilemek üzere gönderilecek bir beklenen

modele yol açmaktadır. Bu da modeller arasındaki ağ uyumunu kolaylaştırmak için düşük ve yüksek katmanlar arasındaki rezonansı oluşturur.

Ağ normalde biyolojik modellemede kullanılır. Bununla birlikte bazı mühendislik uygulamaları da vardır. Bu ağ yapısının en büyük sınırlaması gürültüye olan duyarlılığıdır. Giriş vektördeki küçük miktarda bir gürültü bile iyi bir ağın model eşleme yeteneğini karıştırmaktadır.

3. YAPAY SİNİR AĞLARININ YAPISAL SİSTEMLERE UYGULANMASI


3.1. İç Basınç Altında İnce Cidarlı Silindirik Kabuğun Analizi

İç basınca maruz ince cidarlı silindirik kabuğun iç yüzeyine Şekil 3.1’de görüldüğü gibi düzgün yayılı bir $p (N/mm^2)$ yükü etki etmektedir. Dairesel silindirik kabuğun eksenine ait çap d , kabuğun et kalınlığı t ve çubuk boyu ℓ alınırsa, Şekil 3.1c’deki p iç basıncından dolayı kabuğun eksenî doğrultusundaki gerilme

$$\sigma_x = \frac{pd}{4t}, \text{ dir.} \quad (3.1)$$

Şekil 3.1c’deki çember doğrultusundaki gerilme

$$\sigma_y = \frac{pd}{2t}, \text{ dir.} \quad (3.2)$$



Şekil 3.1a. P İç Basınca Maruz İnce Cidarlı Uzun Silindirik Kabuk
Şekil 3.1b. P Basıncından Dolayı Oluşan Kabuğun Uçlarındaki Eksenel Gerilme
Şekil 3.1c. Çapsal Bir Yüzey Tarafından Şekillendirilen Yarım Kabuk
Şekil 3.1d. Kabuk Duvarındaki Herhangi Bir Noktadaki Gerilmenin Durumu

Burada ϵ_x kabuk eksenine paralel doğrultuda olup hacimsel değişime yol açar. Bu doğrultudaki uzama oranı

$$\epsilon_x = \frac{pd}{2tE} \left(\frac{1}{2} - \nu \right) \quad (3.3)$$

olup benzer şekilde kabuğun çevresel uzama miktarı;

$$\epsilon_y = \frac{pd}{2tE} \left(1 - \frac{1}{2} \nu \right) \quad (3.4)$$

elde edilir. Kabuğun boyundaki artış $\epsilon_x \ell$ iken çevredeki artış $\epsilon_y \pi d$ ’dir. Kabuğun hacmindeki artış;


$$\Delta V = \frac{\pi d^2 L}{4} \frac{pd}{tE} \left(\frac{5}{4} - \nu \right) \quad (3.5)$$

Buradan hacimsel gerilme

$$\frac{\Delta V}{\frac{\pi d^2 L}{4}} = \frac{pd}{tE} \left(\frac{5}{4} - \nu \right) \text{ olarak bulunur [19].} \quad (3.6)$$

3.2. İç Basınç Altında İnce Cidarlı Silindirik Kabuğun YSA ile Analizi

İnce cidarlı silindirik bir kabuk 2000 mm’lik bir iç çapa ve 20 mm’lik bir kalınlığa sahiptir. Kabuğun gerilmeye bağlı dayanımı 400 N/mm² ve emniyet sayısı 6 alınarak kabuktaki güvenilir basınç ve bu basınca maruz olan kabuğun hacmindeki yüzdelik artış belirlenmiştir. Elastisite modülü E=2x10⁵ N/mm² ve poisson oranı v=0.3 olarak alınmıştır.



Şekil 3.2. İnce Cidarlı Silindirik Kabuk için Oluşturulan Ağ Yapısı


Bu uygulama için kullanılan YSA’da Şekil 3.2’de görüldüğü gibi 5 girdi (Yük, boru kalınlığı, boru çapı, Elastisite Modülü ve Poisson oranı), 1 çıktı ve 10 nörondan oluşan 1 gizli katman kullanılmıştır. Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 35 adet örnek bulunmaktadır. Ağın eğitim setinde kullanılan değerler Tablo 3.1’de verilmiştir.

Tablo 3.1. İnce Cidarlı Silindirik Kabuk için Hazırlanan Eğitim Seti

Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
P	Yük	1–3.5 N/mm ²
d	Boru kalınlığı	1000–4000 mm
t	Boru çapı	13–30 mm
E	Elastisite modülü	100000–325000 N/mm ²
v	Poisson oranı	0.1–0.7
ΔV	Kabuğun yüzdelik hacim artışı	% 0.028–0.299

Bu örnekler ağa sunulurken giriş ve çıkış değerleri normalize edilmiştir. Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.6 olarak seçildiğinde

ağ daha uygun sonuçlar vermiştir. Bu parametrelerin kullanıldığı ağ bir paket programda eğitilmiş ve test edilmiştir. Bu ağın iterasyona bağlı hata değişim oranı Şekil 3.3’de verilmiştir.



Şekil 3.3. YSA'nın İterasyona Bağlı Hata Değişim Grafiği

Ağın eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setindeki örneklerden tamamen farklı değerler kullanılarak ağ test edilmiştir. Ağın test setinde kullanılan örnekler ve sonuçların karşılaştırılması Tablo 3.2’de verilmiştir.

Tablo 3.2. İnce Cidarlı Silindirik Kabuk için Hazırlanan Test Seti

Test No	Giriş					Çıkış	
	P	d	t	E	ν	Sayısal sonuç	YSA
1	2.6	1800	26	285000	0.6	0.041	0.046
2	1.5	2000	19	210000	0.4	0.064	0.060
3	1.8	3250	20	220000	0.2	0.139	0.130
4	2.5	3500	28	155000	0.3	0.191	0.190
5	2.6	1900	17	230000	0.4	0.107	0.110
6	1.5	2700	23	270000	0.1	0.075	0.080
7	1.7	2200	25	250000	0.6	0.039	0.038
8	3	3800	29	140000	0.3	0.266	0.240
9	1.6	2700	21	245000	0.5	0.062	0.057
10	2.8	1700	24	315000	0.4	0.054	0.059


Bu problemin Megson [19] tarafından çözümü neticesinde sonuç % 0.063 olarak bulunmuştur. Verilen eğitim seti ve öğrenme oranının Şekil 3.2’deki YSA’ya uygulanması sonucunda % 0.065 olarak elde edilmiştir. Kabuğun hacmindeki artış Megson tarafından bulunan sonuç referans alınırsa yeterli hassasiyette bulunmuş sayılır.

3.3. İnce Silindirik Borunun Gerilme Analizi

O merkezi boyunca α rad/sn açısal hız ile döndürülen dairesel bir ince halka, Şekil 3.4’de görüldüğü gibi dışarıya doğru etki eden bir atalet kuvvetine maruzdur. Halkanın Merkez ile θ açısı yapan bir AB yayı için atalet kuvveti

$$F = m\omega^2 r \text{ 'dir.} \quad (3.7)$$

Burada m , AB elemanın kütlesidir.



Şekil 3.4. Dönen İnce Halka, Kesiti ve Kuvvet Diyagramı

ρ malzemenin yoğunluğu ve A halkanın kesit alanı ise

$$m = \rho \times r \theta \times A \quad (3.8)$$

Buradan

$$F = \rho \theta A \omega^2 r^2 \quad (3.9)$$

bulunur.

Şekil 3.4'de görülen elemana etki eden F atalet kuvveti etkisinde halkanın A ve B noktalarında oluşan T kuvvetleri ile dengelenir. Kuvvet diyagramından, θ 'nin küçük olduğu durumda:

$$T\theta = F = \rho \theta A \omega^2 r^2 \quad (3.10)$$

Böylece

$$T = \rho A \omega^2 r^2 \text{ elde edilir.} \quad (3.11)$$

c , T den dolayı oluşan gerilme ise

$$c \times A = T \quad (3.12)$$

$$\sigma \times A = \rho A \omega^2 r^2 \quad (3.13)$$

$$\sigma = \rho \omega^2 r^2 = \rho v^2 \quad (3.14)$$

Burada v doğrusal hız, ortalama yarıçap r dir

3.4. YSA ile İnce Silindirik Borunun Gerilme Analizi

Bu uygulamada, dönen ince silindirik bir borudaki maksimum gerilmeyi YSA kullanarak analiz edeceğiz. Problemde borunun ortalama yarıçapı 3 mm, dakikada yaptığı devir sayısı 500000 devir/dakika ve çeliğin yoğunluğu 7.8 Mg/m^3 'dir.


Problem için geri yayılımlı yapay sinir ağı kullanılmıştır. Bu ağda 1 giriş katmanı, 1 ara katman ve 1 çıkış katmanı kullanılmıştır. Girdi katmanında üç işlem elemanı bulunmaktadır:

a) Borunun ortalama yarıçapı (m)

b) Borudaki çeliğin yoğunluğu (Kg/m^3)

c) Borunun yaptığı devir sayısı (rad/s)

Ara katmanda 10 adet yapay nöron kullanılmıştır. Ağın çıkışı ise borudaki maksimum gerilmedir (Şekil 3.5).



Şekil 3.5. İnce Silindirik Boru için Kullanılan Yapay Sinir Ağı

Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 29 adet örnek bulunmaktadır. Bu eğitim setinin ilk 15 örneği Tablo 3.3’de verilmiştir. Bu giriş değerleri normalize edilerek ağa sunulmuştur. Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.8 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak çift yönlü sigmoid fonksiyonu kullanılmıştır. Ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır. Bu öğrenme yöntemi, bütün işleme elemanlarının anlık hatalarını en aza indirmeye çalışır. Bu hata azaltma işlemi, kabul edilebilir doğruluğa ulaşana kadar ağırlıklar devamlı olarak derlenir.

Tablo 3.3. İnce Silindirik Boru için Hazırlanan Eğitim Seti

Örnek	r (m)	ρ (kg/m^3)	ω (rad/s)	σ (MN/m^2)
1	0.0050	10000	20943.95	109.662
2	0.0060	3550	36651.91	171.688
3	0.0010	11500	78539.82	70.937
4	0.0040	8850	10471.98	15.528
5	0.0045	5750	26179.94	79.805
6	0.0020	15000	36651.91	80.601
7	0.0035	4800	68067.84	272.434
8	0.0075	8750	24085.54	285.524
9	0.0015	6500	78539.82	90.214
10	0.0055	5550	39269.91	258.903
11	0.0100	2500	23561.94	138.791
12	0.0080	7000	13089.97	76.763
13	0.0070	12500	7853.93	37.782
14	0.0035	9500	34033.92	134.798
15	0.0035	5250	23823.74	125.894

Ağın eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setindeki örneklerden tamamen farklı değerler kullanılmış ve elde edilen sonuçlar Tablo 3.4’de karşılaştırılmıştır.


Tablo 3.4. Silindirik Boru için Verilen Test Seti

Test No	Giriş			Çıkış	
	r	ρ	ω	σ	
				Sayısal Sonuç	YSA
1	0.060	5550	225000	110.922	111.21
2	0.095	4000	230000	209.42	208.07
3	0.050	3000	462500	175.93	177.65

Yapay sinir ağını eğittikten ve test ettikten sonra; problem için verilen değerler ağa sunulursa elde edilen gerilme değeri 192.9 MN/m^2 olarak bulunur. Bu problemin J. Hannah ve M. J. Hillier [20] tarafından çözülmesi sonucunda elde edilen gerilme değeri ise 193 MN/m^2 ’dir. Gerek test setinden elde edilen sonuçlar ve gerekse problemin gerçek değerlerinden elde edilen sonuç göz önüne alındığında ağın yeterli hassasiyette sonuçlar bulduğu görülür.

3.5. İnce Silindirik Tüpün Burulma Analizi

Şekil 3.6’da gösterilen ince tüpün yarıçapı r ve et kalınlığı t ’dir. Tüpün her iki ucuna T burulma momenti uygulanırsa, bir ucu diğerine bağlı olarak burulacaktır. Tüp eksenine paralel olan AB , döndürülerek AB' konumunu alır. OB yarıçapı yine doğru olarak kalır ve küçük θ açısı dönerek OB' konumunu alır.



Şekil 3.6. Tüp Sistem

Kayma gerilmesi

$$\phi \approx \frac{BB'}{AB} = \frac{r\theta}{l} (\text{rad}) \text{ 'dır.} \quad (3.15)$$

Tüpün kesit alanındaki kayma kuvveti

$$F = \frac{T}{r} \quad (3.16)$$

bu kuvvet tüp ince olduğu zaman $2\pi r t$ alanındaki harekettir. Buradan kayma gerilmesi

$$\tau = \frac{\text{kayma kuvveti}}{\text{alan}} = \frac{F}{2\pi r t} = \frac{T/r}{2\pi r t} = \frac{T}{2\pi r^2 t} \text{ 'dir.} \quad (3.17)$$

$$\text{Kayma modülü } \frac{\tau}{\phi} = G \text{ ve } \phi = \frac{r\theta}{l} \quad (3.18)$$

o halde

$$\frac{\tau}{\phi} = \frac{\tau}{r\theta/l} = G \quad (3.19)$$

buradan

$$\frac{\tau}{r} = \frac{G\theta}{l} \quad (3.20)$$

bulunur.


3.6. YSA ile İnce Silindirik Tüpün Burulma Analizi

Bu uygulamada, ince silindirik bir tüpün burulma açısını YSA ile analiz edeceğiz. Uygulama için kullanılan değerler; silindirik tüpün çapı 25 mm, kalınlığı 1.5 mm, uzunluğu 300 mm'dir. Müsaade edilebilir kayma gerilmesi 35 N/mm² ve malzemenin kayma modülü 80 KN/mm² dir.

Problem için geri yayımlı yapay sinir ağı kullanılmıştır. Bu ağda 1 giriş katmanı, 1 ara katman ve 1 çıkış katmanı kullanılmıştır (Şekil 3.7). Girdi katmanında dört işlem elamanı bulunmaktadır:

- a) Silindirik tüpün çapı (r, mm)
- b) Silindirik tüpün uzunluğu (l, mm)
- c) Müsaade edilebilir kayma gerilmesi (τ , N/mm²)
- d) Malzemenin kayma modülü (G, N/mm²)

Ara katmanda 8 adet yapay nöron kullanılmıştır. Ağın çıkışı ise bu giriş değerlerine maruz kalan silindirik tüpün burulma açısıdır.



Şekil 3.7. İnce Silindirik Tüp için Oluşturulan YSA Modeli

Girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 39 adet örnek bulunmaktadır. Bu eğitim setinin ilk 10 örneği Tablo 3.5’de verilmiştir. Ağın eğitiminde kullanılan giriş değerleri normalize edilerek ağı sunulmuştur. Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.4 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak çift yönlü sigmoid fonksiyonu kullanılmıştır. Öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır.

Tablo 3.5. Silindirik Tüp için Hazırlanan Eğitim Seti

Örnek No	r (mm)	l (mm)	G (N/mm ²)	τ (N/mm ²)	θ (rad)
1	10.0	450	100000	40.0	0.0180
2	17.5	250	45000	50.0	0.0159
3	20.0	500	35000	15.0	0.0107
4	9.0	550	95000	25.0	0.0161
5	12.0	750	125000	20.0	0.0100
6	27.0	200	15000	17.5	0.0086
7	8.0	150	85000	45.0	0.0099
8	16.0	800	28000	7.5	0.0134
9	26.0	225	17500	12.5	0.0062
10	33.0	275	12500	14.0	0.0093

Ağın eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setinde kullanılan örneklerden farklı örnekler ağı sunulmuş ve elde edilen sonuçlar Tablo 3.6’da karşılaştırılmıştır.


Tablo 3.6. Silindirik Tüpün Test Seti

Test No	Giriş				Çıkış	
	r	l	G	τ	θ	
					Sayısal Sonuç	YSA
1	16	400	40000	21	0.0105	0.0106
2	18	500	35000	22	0.0175	0.0174
3	21	350	30000	32	0.0167	0.0167

Yapay sinir ağını eğittikten ve test ettikten sonra bu uygulamada kullanılan değerleri ağıya verdiğimizde sonuç 0.0106 (rad) bulunmuştur. Bu problemin J. Hannah ve M. J. Hillier [20] tarafından çözülmesi sonucunda elde edilen sonuç ise 0.0105 (rad)'dır. Test setinden elde edilen sonuçlar ile problemin gerçek sonucu göz önüne alındığında ağıın yeterli hassasiyette sonuçlar bulduğu görülür.


3.7. T Kesitli Kirişin Analizi

Bu uygulamada, Şekil 3.8'de görülen T tablalı kirişin taşıma gücü momentleri ve gerekli olan donatı alanları analiz edilmiştir. Problemde tablalı kirişin alt genişliği (b_w) 250 mm, tablalı kirişin üst genişliği (b) 600 mm, yüksekliği (h) 500 mm, faydalı yüksekliği (d) 460 mm, döşeme kalınlığı (h_f) 100 mm ve tasarım momenti (M_d) 300 kNm verilmiştir. Ayrıca problemde $f_{yd}=365 \text{ MPa}$, $f_{cd}=13 \text{ MPa}$, $f_{ctd}=1 \text{ MPa}$ değerleri verilmiştir.




Şekil 3.8. Tablalı Kirişin En Kesiti

Problem için çok katmanlı yapay sinir ağlarından olan geri yayımlı yapay sinir ağı kullanılmıştır. Bu ağda 1 giriş katmanı, 1 ara katman ve 1 çıkış katmanı kullanılmıştır. Girdi katmanında altı işlem elemanı bulunmaktadır. Ara katmanda 10 adet yapay nöron kullanılmıştır. Ağıın çıkışı ise tablalı kirişin taşıma gücü momentleri, kanatların donatı alanı ve gövdenin donatı alanıdır (Şekil 3.9).



Şekil 3.9. Tablalı Kiriş için Geliştirilmiş YSA Modeli

Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 43 adet örnek bulunmaktadır. Bu örneklerde tablalı kirişin alt genişliği 200–380 mm, tablalı kirişin üst genişliği 500–750 mm, yüksekliği 420–660 mm, faydalı yüksekliği 380–620 mm, döşeme kalınlığı 75–125 mm ve tasarım momenti 261–536 kNm arasında değerler verilerek modellenmiştir. Giriş ve çıkış değerleri normalize edilerek ağa sunulmuştur. Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.95 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak giriş ve ara katmanda ‘logsig’, çıkış katmanında ise ‘purelin’ fonksiyonları kullanılmıştır.



Şekil 3.10. Tablalı Kirişin Eğitim Hatasının İterasyona Bağlı Olarak Değişimi

Ağın eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setinde kullanılan örneklerden farklı örnekler ağa sunulmuş ve elde edilen sonuçlar sayısal sonuçlarla karşılaştırılmıştır.

Yapay sinir ağı eğitildikten ve test edildikten sonra uygulama için verilen değerler ağa sunulmuş ve sonuçlar Tablo 3.7’de verilmiştir. Bu sonuçlar ışığında yapay sinir ağlarının analiz problemlerinde başarıyla uygulanabileceği görülmüştür.

Tablo 3.7. Tablalı Kirişin Karşılaştırılması

	Sayısal sonuç [21]	YSA
$M_r (kNm)$	271.8	272.4
$As_f (mm^2)$	1059.6	1061.3
$As_w (mm^2)$	977.5	978.9

3.8. Kısa Konsollarda Donatı Tayini

3.8.1. Kısa Konsollar

Kısa konsollarda yükleme noktasından mesnet yüzüne olan uzaklığın (a_v), mesnetteki faydalı yüksekliğe oranı 1.0’den büyük olmayan konsollar, kısa konsol olarak adlandırılmaktadır. Kısa konsollar genellikle sanayi yapılarında ve köprülerde kullanılmaktadır.

Kısa konsolların taşıma gücü hesapları ve donatı detayları normal konsollardan farklıdır. Kısa konsola uygulanan yükün büyük bir bölümü konsolda kurgusal (fiktif) olarak olduğu kabul edilen beton basınç çubuğu ile mesnede aktarılmaktadır.


Özel önlemler alınmayan durumlarda, konsola oturan kirişlerde sıcaklık değişimi ve büzülme gibi olaylar nedeni ile oluşan kılma ve uzamalar, konsol üzerinde yatay kuvvetler oluştururlar. Bu yatay kuvvet H_d ile gösterilmekte ve bunun için yük katsayısı 1.6 olarak uygulanmaktadır. Her zaman çekme olarak hesaba katılacak olan bu yatay kuvvet aşağıdaki şartı sağlamalıdır.

$$H_d \geq 0.2V_d \quad (3.21)$$

Konsol için tasarım kesme kuvveti aşağıdaki koşulu sağlamalıdır. Bu koşul sağlanmıyorsa kesit boyutları büyütülebilir, ya da beton kalitesi artırılabilir. Ancak kesiti büyütme daha uygundur.

$$V_d \leq 0.22f_{cd}b_wd \quad (3.22)$$

Toplam çekme donatısı (A_{st}); eğilme ve eksenel kuvvet (H_d) için hesaplanan donatıların toplamıdır. Toplam çekme donatısı A_s eğilme donatısı alanına ve A_n kısa konsolda yatay kuvvet için gerekli donatı alanına bağlı olarak hesaplanmaktadır [21].




Şekil 3.11. Kısa Konsol Kesiti ve Boyutlandırma

3.8.2.YSA ile Kısa Konsollarda Donatı Tayini

Bu uygulamada, kısa konsoldaki eğilme donatısı alanı ile yatay kuvvet için gerekli olan donatı alanı YSA kullanarak analiz edilmiştir. Şekil 3.12’de görülen kısa konsolun genişliği 300 mm, konsol yüksekliği 500 mm, faydalı yüksekliği 450 mm, kirişe gelen yatay yük 40 KN,


yüklemeye noktasından mesnet yüzüne olan uzaklık 200 mm, kirişe gelen hareketli yük 100 kN, sabit yük ise 150 kN olarak verilmiştir.



Şekil 3.12. Uygulamada Kullanılan Kısa Konsolun Şekli ve Verileri

Problem için ileri beslemeli yapay sinir ağı kullanılmıştır. Bu ağda 1 giriş katmanı, 1 ara katman ve 1 çıkış katmanı kullanılmıştır. Girdi katmanında yedi işlem elemanı bulunmaktadır:

- Konsol kiriş genişliği (mm)
- Konsol kiriş yüksekliği (mm)
- Konsol kirişin faydalı yüksekliği (mm)
- Konsol kirişe gelen yatay yük (kN)
- Yüklemeye noktasından mesnet yüzüne olan uzaklık (mm)
- Konsol kirişe gelen hareketli yük (kN)
- Konsol kirişe gelen sabit yük (kN)



Şekil 3.13. Kısa Konsol Kiriş için Kullanılan Yapay Sinir Ağı

Şekil 3.13’de görüldüğü gibi ara katmanda 10 adet yapay nöron kullanılmıştır. Ağın çıkışları ise eğilme donatısı alanı ve kısa konsolda yatay kuvvet için gerekli olan donatı alanıdır.

Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 36 adet örnek bulunmaktadır. Giriş ve çıkış değerleri normalize edilerek ağa sunulmuştur. Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.8 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak çift yönlü sigmoid fonksiyonu, ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır.

Tablo 3.8. Eğitim Seti için Kullanılan Değerler


Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X ₁	Konsol kiriş genişliği	250–480 mm
X ₂	Konsol kiriş yüksekliği	350–560 mm
X ₃	Konsol kirişin faydalı yüksekliği	300–510 mm
X ₄	Konsol kirişe gelen yatay yük	25–55 kN
X ₅	Yükleme noktasından mesnet yüzüne olan uzaklık	175–230 mm
X ₆	Konsol kirişe gelen hareketli yük	75–130 kN
X ₇	Konsol kirişe gelen sabit yük	120–180 kN
Y ₁	Konsol kirişin eğilme donatısı alanı	456.22–904.05 mm ²
Y ₂	Kısa konsolda yatay kuvvet için gerekli olan donatı alanı	166.57–249.86 mm ²

Ağın eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setindeki örneklerden tamamen farklı değerler kullanılarak ağ test edilmiş ve elde edilen sonuçlar Tablo 3.9’da karşılaştırılmıştır.

Tablo 3.9. Hazırlanan Test Seti

Test No	Giriş							Çıkış			
	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	Y ₁		Y ₂	
								Sayısal Sonuç	YSA	Sayısal Sonuç	YSA
1	400	520	470	45	180	95	145	505.31	503.97	200	200
2	450	450	400	30	215	125	175	876.49	876.32	249.32	249.40
3	420	530	480	55	190	110	175	619.29	620.95	237.80	237.62
4	475	550	500	30	205	100	130	512.46	511.78	190.68	190.52
5	350	420	370	40	210	115	160	849.13	851.28	228.49	228.52

Yapay sinir ağını eğittikten ve test ettikten sonra; problem için verilen değerler ağa sunulursa elde edilen eğilme donatısı alanı 607.87 mm², yatay kuvvet için gerekli donatı alanı ise 208.26 mm² olarak bulunur. Bu problemin sayısal çözümü [21] sonucunda elde edilen eğilme donatısı alanı 607.30 mm², yatay kuvvet için gerekli donatı alanı ise 208.22 mm²’dir.



Şekil 3.14. Kısa Konsol için Hazırlanan YSA'nın Hatasının İterasyona Bağlı Değişimi

3.9. Silis Dumanı Katkılı Betonların Çarpma Dayanımının Tespit Edilmesi

3.9.1. Deney Yöntemi

10 cm'lik kübik beton numuneleri, ağırlığı 13.8 Kg olan bir cismin 25 cm ve 35 cm'den serbest olarak numune üzerine düşürülmesi ile ardışık çarpma etkisine maruz bırakılmıştır. Çarpma öncesi ve sonrası beton numuneleri üzerinden Ultrasonic Puls Cihazı ile PGH değerleri alınmıştır. PGH değerleri referans alınarak darbe sonrasında betonda beklenen eşdeğer basınç dayanımı (EPD) bulunmuştur [22].


3.9.2. Silis Dumanı Katkılı Betonların Çarpma Dayanımının YSA ile Tespit Edilmesi

Bu uygulamada, yapılan deney [22] dataları kullanılarak silis dumanı katkılı betonların çarpma dayanımı YSA kullanarak tespit edilmiştir. Uygulamada ardışık çarpma sayısı 4, numunenin ağırlık kaybı 55.6 gr, darbe öncesi PGH değeri 4.40, darbe sonrası 1.80 olarak ölçülmüş olan numunenin çarpma dayanımını tespit edilmiştir.

Problem için geri yayımlı yapay sinir ağı kullanılmıştır. Bu ağda 1 giriş katmanı, 2 ara katman ve 1 çıkış katmanı kullanılmıştır. Girdi katmanı, 4 işlem elamanından meydana gelmektedir. Bunlar:

- Ardışık çarpma sayısı
- Numunenin ağırlık kaybı (gr)
- Darbe öncesi PGH hızı (km/sn)
- Darbe sonrası PGH hızı (km/sn)

Her iki ara katmanda da 8 adet yapay nöron kullanılmıştır. Ağın çıkışı çarpma dayanımıdır (Şekil 3.15).



Şekil 3.15. Çarpma Dayanımının Tespiti için Kullanılan Yapay Sinir Ağı

Deney numunelerinden [22] bazıları eğitim setinde bazıları ise test setinde kullanılmıştır. Ağın eğitilmesi için oluşturulan eğitim setinde 17 adet örnek bulunmaktadır (Tablo 3.10). Bu giriş değerleri normalize edilerek ağa sunulmuştur. Yapılan denemeler sonucunda iki ara katman uygun görülmüş ve öğrenme oranı 0.8 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak çift yönlü sigmoid fonksiyonu kullanılmıştır. Ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır. Bu öğrenme yöntemi, bütün işleme elemanlarının anlık hatalarını en aza indirmeye çalışır. Bu hata azaltma işlemi, kabul edilebilir doğruluğa ulaşana kadar ağırlıklar devamlı olarak derlenir. Bu parametreler kullanılarak paket programda YSA eğitilir. Bu ağın iterasyona bağlı hata değişim grafiği de Şekil 3.16’da verilmiştir.

Tablo 3.10. Çarpma Dayanımının Tespiti için Hazırlanan Eğitim Seti


Beton Numunesi	Ardışık çarpma sayısı (X_1)	Ağırlık kaybı (X_2)	Darbe öncesi PGH (X_3)	Darbe sonrası PGH (X_4)	Çarpma dayanımı (Y)
K	5	957.1	3.41	1.24	13.0
K	4	686.3	3.38	1.60	16.0
F10	5	50.8	4.28	1.79	18.0
F10	4	63.1	4.31	1.81	18.0
F20	5	86.4	4.38	1.90	20.0
F20	4	46.2	4.52	1.79	18.0
S10	5	76.6	4.21	1.64	17.5
S10	4	70.8	4.30	1.76	18.0
S20	5	62.6	4.39	1.86	20.0
S20	4	55.6	4.40	1.80	18.0
KA	5	129.6	4.18	1.40	15.0
KA	4	46.1	4.13	1.88	18.5
F10A	5	100.1	4.96	1.91	20.0
F15A	4	60.4	5.17	2.12	20.5
S10A	5	88.1	4.72	2.01	20.5
S15A	4	46.3	4.81	2.10	20.5

Ağın eğitimi tamamlandıktan sonra eğitim setinde kullanılan numune örneklerinden farklı örnekler kullanılarak ağın performansı test edilmiş ve elde edilen sonuçlar Tablo 3.11’de karşılaştırılmıştır.

Tablo 3.11. Çarpma Dayanımının Tespiti için Verilen Test Seti

Test No	Giriş				Çıkış	
	X ₁ (Adet)	X ₂ (gr)	X ₃ (km/sn)	X ₄ (km/sn)	Çarpma dayanımı (MPa)	
					Deney Sonucu	YSA
F30	5	98.4	4.72	1.73	18.000	18.009
S20A	5	76.0	5.12	2.06	20.500	20.501
S30	4	70.1	4.70	1.79	18.000	18.007
F15	4	76.1	4.43	1.86	18.500	18.008
S15A	5	69.0	4.86	2.04	20.500	20.507
F10A	4	88.4	5.10	2.04	20.500	20.472
F30	4	64.0	4.72	1.88	18.500	18.495

Yapay sinir ağını eğittikten ve test ettikten sonra; problem için verilen değerler ağı sunulursa; numunenin çarpma dayanımı 18.0 MPa olarak bulunur. Bu değer yapılmış olan deney [22] sonucunda da 18.0 MPa olarak bulunmuştur. Gerek test setinden elde edilen sonuçlar ve gerekse problemin gerçek değerlerinden elde edilen sonuç göz önüne alındığında ağın yeterli hassasiyette sonuçlar bulduğu görülür.



Şekil 3.16. Sinir Ağına İterasyona Bağlı Hata Değişim Grafiği

3.10. Yalıtım Hesaplarında Yapay Sinir Ağlarının Kullanımı

3.10.1. Isı Yalıtımı (Kontrolü)

Binalarda ısı yalıtımı; mevsim şartlarına göre binayı ısıtmak veya soğutmak için sağlanan soğuk ya da sıcak havanın dışarıya kaçmasını-girmesini önleyerek ısı ekonomisi ve ısı konfor sağlamak amacıyla yapılır. Bu nedenle ısı yalıtımında amaç; kışın bina ısısının dışa

kaçışını yavaşlatarak, ısıtma enerjisi tüketimini azaltmak ve iç mekânın bütününde dengelenmiş bir sıcaklık ortamının devamını sağlamaktır.

İçinde yaşadığımız konutlarda ısı yalıtım amaçlı konforu sağlamak ve optimum şartlarda sıcaklık dengesini kurmak, yapılarda kullanılan malzemenin seçimi ile direkt ilgili bir durumdur. Seçilen malzemenin hangi türden bir yapı malzemesi olursa olsun, ısısal yalıtım etkileri ve ısı geçirimlilik karakteristiği analiz edilerek, irdelenmelidir. Yapılarda iç hava sıcaklığının ve buna bağlı olarak yapı kesitini oluşturan (duvarda, tavanda, tabanda) elemanların iç yüzey sıcaklıklarının belli değerlerde olması gerekmektedir. Yapılan literatür araştırmaları, iç ortam sıcaklığının 18-20°C, yapı elemanı sıcaklığı ise 16-18°C olması arzu edilen konfor şartlarının sağlanabileceğini göstermiştir [23].

Binalarda ısıtma enerjisi ihtiyacı dış duvar türüne bağlı olarak değişmektedir. İçeriden dışarıya sıcaklık kaçışının ölçüsü “U” (veya “k”) ısı geçirgenlik kat sayılarıdır. Birimi W/m²K’dir. U katsayısı, kısım “sıcak içeriden soğuk dışarıya” sabit koşullardaki ısı akımını ifade eder. Yüksek U katsayısı kötü ısı yalıtımı, düşük U katsayısı ise iyi ısı yalıtımı demektir.

3.10.2. Tuğla Duvardaki Yalıtım Kalınlığının Yapay Sinir Ağları ile Tespiti

Bu uygulamada, tuğla duvardaki ısı geçiş katsayısını ve ısı akış yoğunluğunu YSA kullanarak analiz edip ve yalıtım gerektiği takdirde kullanılacak yalıtım malzemesinin minimum kalınlığını yine YSA kullanarak bulacağız. Uygulamada tuğla duvarın kalınlığı 19 cm, iç ve dış sıva kalınlıkları 2 cm, iç ortam sıcaklığı 19 °C, dış ortam sıcaklığı 5.5 °C alınmıştır.




Şekil 3.17. Uygulamada Kullanılan Tuğla Duvarın Yalıtımdan Önceki ve Sonraki Durumu

Problem için geri yayımlı yapay sinir ağı kullanılmıştır. Bu ağda 1 giriş katmanı, 1 ara katman ve 1 çıkış katmanı kullanılmıştır. Girdi katmanında beş işlem elemanı bulunmaktadır:

- İç sıva kalınlığı (m)
- Dış sıva kalınlığı (m)
- Tuğla kalınlığı (m)
- İç ortam sıcaklığı (°C)

e) Dış ortam sıcaklığı (°C)

Ara katmanda 5 adet yapay nöron kullanılmıştır. Ağın çıkışları ise duvardaki ısı geçiş katsayısı ve ısı akış yoğunluğudur (Şekil 3.18).



Şekil 3.18. Tuğla Duvar için Tercih Edilen Yapay Sinir Ağı

Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 40 adet örnek bulunmaktadır. Giriş ve çıkış değerleri normalize edilerek ağa sunulmuştur. Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.75 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu, ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır.

Tablo 3.12. Tuğla Duvar için Hazırlanan Eğitim Setinde Kullanılan Değerler

Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X_1	İç sıva kalınlığı	0.01–0.02 m
X_2	Dış sıva kalınlığı	0.01–0.02 m
X_3	Tuğla kalınlığı	0.085–0.13–0.19 m
X_4	İç ortam sıcaklığı	16–25 °C
X_5	Dış ortam sıcaklığı	2–12 °C
Y_1	Isı geçiş katsayısı	1.597321–2.643822 W/m ² K
Y_2	Isı akış yoğunluğu	13.62727–37.73234 W/m ²

Ağın eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setindeki örneklerden tamamen farklı değerler kullanılarak ağ test edilmiş ve elde edilen sonuçlar Tablo 3.13’de karşılaştırılmıştır.

Tablo 3.13. Tuğla Duvar için Hazırlanan Test Seti


Test No	Giriş					Çıkış			
	X_1	X_2	X_3	X_4	X_5	Y_1		Y_2	
						Sayısal Sonuç	YSA	Sayısal Sonuç	YSA
1	0.011	0.015	0.085	17	6	2.6161	2.6169	28.777	28.783
2	0.018	0.018	0.135	21	8	1.9859	1.9854	25.816	25.816
3	0.013	0.014	0.19	23	10	1.6203	1.6203	21.064	21.064

Yapay sinir ağını eğittikten ve test ettikten sonra; problem için verilen değerler ağı sunulursa elde edilen ısı geçiş katsayısı $1.588 \text{ W/m}^2\text{K}$, ısı akış yoğunluğu ise 21.448 W/m^2 olarak bulunur. Bu problemin sayısal çözümü [23] sonucunda elde edilen ısı geçiş katsayısı $1.588 \text{ W/m}^2\text{K}$, ısı akış yoğunluğu ise 21.445 W/m^2 'dir.

Burada, TS 825'e göre yapılacak bir U kontrolü için TS 825 EK 1-C kullanılır. 3. bölge için okunan değer $U_D=0.50 \text{ W/m}^2\text{K}$ 'dır. Uygulamadaki yapı bileşeni için hesaplanan $U_1=1.59 \text{ W/m}^2\text{K}$ olup, tavsiye edilen değer ile kıyaslandığında yalıtımın zorunlu olduğu görülür. Bu sebeple yalıtım malzemesinin kalınlığını hesaplamak için yine geri yayımlı bir yapay sinir ağı kullanılmıştır. 1 giriş katmanı, 1 ara katman ve 1 çıkış katmanı kullanılmış ve girdi katmanı elemanları aşağıda verilmiştir.

- a) İç sıva kalınlığı (m)
- b) Dış sıva kalınlığı (m)
- c) Tuğla kalınlığı (m)
- d) İç ortam sıcaklığı ($^{\circ}\text{C}$)
- e) Dış ortam sıcaklığı ($^{\circ}\text{C}$)

Ara katmanda 7 adet yapay nöron kullanılmıştır. Ağın çıkışı ise duvarda kullanılan yalıtım malzemesinin kalınlığıdır (Şekil 3.19). Yalıtım malzemesi olarak mineral yün tercih edilmiştir.



Şekil 3.19. Yalıtım Malzemesinin Kalınlığını Bulmak için Hazırlanan YSA

Diğer ağ için oluşturulan eğitim setindeki 40 adet örnek kullanılarak yalıtım malzemesinin kalınlığını veren çıkışlar elde edilmiştir. Giriş ve çıkış değerleri normalize edilerek ağı sunulmuştur. Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.85 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak çift yönlü sigmoid fonksiyonu, ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır.

Tablo 3.14. Eğitim Setinde Kullanılan Değerler

Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X_1	İç sıva kalınlığı	0.01–0.02 m
X_2	Dış sıva kalınlığı	0.01–0.02 m
X_3	Tuğla kalınlığı	0.085–0.13–0.19 m
X_4	İç ortam sıcaklığı	16–25 °C
X_5	Dış ortam sıcaklığı	2–12 °C
Y_1	Yalıtım malzemesinin kalınlığı	0.055015–0.06487 m

Ağın eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setindeki örneklerden tamamen farklı değerler kullanılarak ağ test edilmiş ve elde edilen sonuçlar Tablo 3.15’de karşılaştırılmıştır.


Tablo 3.15. Tuğla Duvardaki Yalıtım Malzemesi Kalınlığı için Hazırlanan Test Seti

Test No	Giriş					Çıkış	
	X_1	X_2	X_3	X_4	X_5	Y_1	
						Sayısal Sonuç	YSA
1	0.011	0.015	0.085	17	6	0.0647	0.0649
2	0.018	0.018	0.135	21	8	0.0598	0.0596
3	0.013	0.014	0.19	23	10	0.0553	0.0552


Yapay sinir ağını eğittikten ve test ettikten sonra; problem için verilen değerler ağı sunulursa elde edilen malzeme kalınlığı 0.0549 m bulunur. Bu problemin sayısal çözümü [23] sonucunda elde malzeme kalınlığı ise 0.0548 m’dir [24].

3.10.3. Yalıtımsız Duvardaki Isı Kaybının Tespiti

Bu uygulamada, Şekil 3.20’de gösterilen yalıtımsız bir tuğla duvardaki ısı kaybı YSA kullanılarak tespit edilmiştir. Uygulamada kullanılan delikli tuğla kalınlığı 19 cm, iç sıva kalınlığı 2 cm, dış sıva kalınlığı ise 3 cm olarak verilmiş olup iç ortam sıcaklığı 22 °C, dış ortam sıcaklığı -10 °C alınmıştır.

**Şekil 3.20.** Yalıtımsız Duvar

Problem için geri yayımlı yapay sinir ağı tercih edilmiştir. Bu ağda 1 giriş katmanı, 1 ara katman ve 1 çıkış katmanı kullanılmıştır. Girdi katmanında beş işlem elemanı bulunmaktadır (Tablo 3.16). Ara katmanda 10 adet yapay nöron kullanılmıştır. Ağı çıkışı ise duvar iç yüzey sıcaklığıdır (Şekil 3.21).



Şekil 3.21. Yalıtımsız Tuğla Duvar için Hazırlanan YSA Mimarisi

Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 27 adet örnek bulunmaktadır. Giriş ve çıkış değerleri normalize edilerek ağa sunulmuştur. Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.75 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak tangent sigmoid fonksiyonu, ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır. Bu parametreler kullanılarak paket programda YSA eğitilir. Bu ağın iterasyona bağlı hata değişimi Şekil 3.22’de verilmiştir.


Tablo 3.16. Yalıtımsız Duvar için Hazırlanan Eğitim Setinde Kullanılan Değerler

Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X_1	İç sıva kalınlığı	0.01–0.02 m
X_2	Dış sıva kalınlığı	0.01–0.03 m
X_3	Tuğla kalınlığı	0.085/0.13/0.19 m
X_4	İç ortam sıcaklığı	16–25 °C
X_5	Dış ortam sıcaklığı	(-2)–(-12) °C
Y	Duvar iç yüzey sıcaklığı	7.780- 18.456 °C

Ağın eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setindeki örneklerden tamamen farklı değerler kullanılarak ağ test edilmiştir. Ağın test setinde kullanılan örnekler ve sonuçların karşılaştırılması Tablo 3.17’de verilmiştir. Yapay sinir ağını eğittikten ve test ettikten sonra; problem için verilen değerler ağa sunulursa elde edilen duvar iç yüzey sıcaklığı 15.25 °C olarak bulunur. Bu problemin sayısal çözümü [25] sonucunda elde edilen duvar iç yüzey sıcaklığı 15.25 °C’dir.


Tablo 3.17. Yalıtımsız Duvar için Hazırlanan Test Seti

Test No	Giriş					Çıkış	
	X_1	X_2	X_3	X_4	X_5	Sayısal sonuç	YSA
1	0.018	0.021	0.135	21	-8	13.35	13.35
2	0.015	0.022	0.135	15	-11	8.10	8.08
3	0.012	0.023	0.190	17	-4	12.46	12.45
4	0.016	0.020	0.190	25	-9	17.68	17.68
5	0.011	0.015	0.085	21	-6	11.66	11.67


**Şekil 3.22.** Yalıtımsız Tuğla Duvar için Hazırlanan Sinir Ağının İterasyona Bağlı Hata Değişim Grafiği

3.10.4. Yalıtımlı Duvardaki Isı Kaybının Tespiti

Bu uygulamada da, Şekil 3.23’de yalıtımlı bir tuğla duvardaki ısı kaybı YSA kullanarak tespit edilmiştir. Uygulamada kullanılan delikli tuğla kalınlığı 19 cm, iç sıva kalınlığı 2 cm, dış sıva kalınlığı ise 3 cm olarak verilmiş olup iç ortam sıcaklığı 22 °C, dış ortam sıcaklığı -10 °C alınmıştır. Yalıtım malzemesi olarak 5 cm’lik styropor malzemesi kullanılmıştır.

**Şekil 3.23.** Yalıtımlı Duvar

Problem için 1 giriş, 1 ara ve 1 çıkış katmanı bulunan geri yayımlı yapay sinir ağı kullanılmıştır. Girdi katmanında altı işlem elamanı bulunmaktadır. Ara katmanda 10 adet yapay nöron kullanılmıştır. Ağın çıkışı ise yalıtımlı duvarın iç yüzey sıcaklığıdır (Şekil 3.24).



Şekil 3.24. Yalıtımlı Tuğla Duvar için Hazırlanan YSA Mimarisi

Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 27 adet örnek bulunmaktadır. Giriş ve çıkış değerleri normalize edilerek ağa sunulmuştur. Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.80 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak tangent sigmoid fonksiyonu, ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır. Bu parametreler kullanılarak paket programda YSA eğitilir. Bu ağın iterasyona bağlı hata değişimi Şekil 3.25’de verilmiştir.

Tablo 3.18. Yalıtımlı Duvar için Hazırlanan Eğitim Setinde Kullanılan Değerler


Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X_1	İç sıva kalınlığı	0.01 – 0.02 m
X_2	Dış sıva kalınlığı	0.01 – 0.03 m
X_3	Tuğla kalınlığı	0.085 / 0.13 / 0.19 m
X_4	Yalıtım malzemesi kalınlığı	0.035 – 0.065 m
X_5	İç ortam sıcaklığı	16 – 25 °C
X_6	Dış ortam sıcaklığı	(-2) – (-12) °C
Y	Duvar iç yüzey sıcaklığı	14.437 – 23.191 °C

Ağın eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setindeki örneklerden tamamen farklı değerler kullanılarak ağ test edilmiş ve bulunan sonuçlar Tablo 3.19’da karşılaştırılmıştır.

Tablo 3.19. Yalıtımlı Duvar için Hazırlanan Test Seti

Test No	Giriş						Çıkış	
	X_1	X_2	X_3	X_4	X_5	X_6	Sayısal sonuç	YSA
1	0.018	0.021	0.135	0.040	21	-8	18.54	18.52
2	0.015	0.022	0.135	0.055	15	-11	13.24	13.28
3	0.012	0.023	0.190	0.050	17	-4	15.56	15.56
4	0.016	0.020	0.190	0.035	25	-9	22.06	22.03
5	0.011	0.015	0.085	0.045	21	-6	18.72	18.72

Yapay sinir ağını eğittikten ve test ettikten sonra; problem için verilen değerler ağı sunulursa elde edilen iç yüzey sıcaklığı 19.82 °C olarak bulunur. Bu problemin sayısal çözümü [25] sonucunda elde edilen iç yüzey sıcaklığı 19.82 °C'dir.




Şekil 3.25. Yalıtımlı Tuğla Duvar için Hazırlanan Sinir Ağına İterasyona Bağlı Hata Değişim Grafiği

3.10.5 Yalıtımsız Borudaki Isı Kaybının Tespiti

Yüksek sıcaklıkların söz konusu olduğu tesisatta yalıtım daha büyük ısı kazancı ve parasal kazanç sağlamaktadır. Yalıtım kalınlığı arttıkça tasarruf artmakta, ancak yatırım maliyeti de yükselmektedir. Isı yalıtım malzemesinin cins ve kalınlığı belirlenirken, optimum yalıtım kalınlığı belirlenmelidir.


Tesisatta yalıtımın bina yalıtımlarından en önemli farkı, tesisatta karşılaşılan sıcaklık seviyelerinin, binalardaki sıcaklık seviyesinden çok daha yüksek olmasıdır. Binalarda iç ortam sıcaklığı ile dış ortam sıcaklığı arasındaki fark 30–40 °C olmasına karşılık tesisatta karşılaşılan sıcaklıklar bunun çok üzerindedir. Dolayısıyla tesisatta yapılacak iyi bir yalıtımla binalardakilerden çok daha fazla enerji tasarrufu sağlanması söz konusudur.

Yalıtımsız çıplak borularda ısı kayıp hesapları oldukça karışık ve zordur. Dış yüzey sıcaklıklarının çeşitli etkenlere bağlı olarak değişmesi; havanın, rüzgâr hızının sabit olmayışı, rüzgârın şiddeti, yakında bulunan cihazların ısınlama yoluyla etkileri matematiksel yol ile bulunan sonuçların objektif ölçümlere uymamasını yaratır [25].



Şekil 3.26. Yalıtım Uygulanmamış Tesisat Borusu

Şekil 3.26’da gösterilen yalıtımsız borudaki ısı kaybı; tahmin konusunda başarılı sonuçlar veren YSA kullanılarak tespit edilmiştir. Yapılan uygulamada boru çapı 57 mm, boru iç sıcaklığı 120 °C ve dış hava sıcaklığı da 20 °C alınmıştır.



Şekil 3.27. Yalıtımsız Boru için Oluşturulan Ağ Yapısı

Bu uygulamada kullanılan YSA’da Şekil 3.27’de görüldüğü gibi 3 girdi, 1 çıktı ve 8 adet nörondan oluşan 1 gizli katman kullanılmıştır. Eğitim seti için gerekli data çıplak borularda ısı kaybını gösteren diyagram [25] kullanılarak hazırlanmıştır. Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 25 adet örnek bulunmaktadır. Ağın eğitim setinde kullanılan değerler Tablo 3.20’de verilmiştir. Bu örnekler ağa sunulurken değerler normalize edilmiştir.

Tablo 3.20. Yalıtımsız Boru için Oluşturulan Eğitim Setinde Kullanılan Değerler


Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X_1	Boru çapı	32 – 269 mm
X_2	Boru iç sıcaklığı	60 – 350 °C
X_3	Dış hava sıcaklığı	2 – 28 °C
Y	Borudaki ısı kaybı	110 – 3700 Kcal/mh

Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.75 olarak seçildiğinde ağ daha uygun sonuçlar vermiştir (Tablo 3.21). Bu parametrelerin kullanıldığı ağ bir paket programla eğitilmiş ve test edilmiştir. Bu ağın iterasyona bağlı hata değişim oranı Şekil 3.28’de verilmiştir.

Tablo 3.21. Ağ Yapısı ve Öğrenme Oranının Deneme Yoluyla Bulunması

Ağ yapısı	Öğrenme oranı	Hata
3-8-1	0.75	0.17
3-8-1	0.60	6.24
3-8-1	0.90	2.00
3-10-1	0.75	5.48
3-10-1	0.60	7.48
3-10-1	0.90	5.60
3-4-1	0.75	7.35
3-4-1	0.60	0.51
3-4-1	0.90	5.05


Bu problemde 0.75 öğrenme oranı ve Tablo 3.20’de verilen eğitim setinin uygulanması sonucu borudaki ısı kaybı 234 kcal/m tul h bulunmuştur. Bu problemin çözümü [25] neticesinde 230 kcal/m tul h olarak bulunan sonuç göz önüne alındığında yapay sinir ağından yeterli hassasiyette bir sonuç elde edildiği görülür.




Şekil 3.28. Yalıtımsız Boru için Hazırlanan Sinir Ağına İterasyona Bağlı Hata Değişim Grafiği

3.10.6. Yalıtımlı Borudaki Isı Kaybının Tespiti

Bu uygulamada da 318 mm’lik boru çapı, 300 °C’lik boru iç sıcaklığı ve 20 °C’lik dış hava sıcaklığındaki bir boru 160 mm kalınlığında bir yalıtım malzemesi ile yalıtılmıştır (Şekil 3.29). Geri yayımlımlı bir yapay sinir ağı kullanılarak boruda oluşan ısı kaybı tespit edilmiştir.



Şekil 3.29. Yalıtım Malzemesi ile Sarılmış Tesisat Borusu



Şekil 3.30. Yalıtımlı Boru için Oluşturulan Ağ Yapısı

Bu uygulamada kullanılan YSA’da Şekil 3.30’da görüldüğü gibi 4 girdi, 1 çıktı ve 8 adet nörondan oluşan 1 gizli katman kullanılmıştır. Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 25 adet örnek bulunmaktadır. Ağın eğitim setinde kullanılan değerler Tablo 3.22’de verilmiştir. Bu örnekler ağa sunulurken değerler normalize edilmiştir.

Tablo 3.22. Yalıtımlı Boru için Oluşturulan Eğitim Setinde Kullanılan Değerler

Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X ₁	Boru çapı	232 – 469 mm
X ₂	Boru iç sıcaklığı	60 – 350 °C
X ₃	Dış hava sıcaklığı	2 – 28 °C
X ₄	Yalıtım kalınlığı	100 – 280 mm
Y	Borudaki ısı kaybı	42.67 – 165.27 W/m

Yapılan denemeler sonucunda bir ara katman uygun görülmüş ve öğrenme oranı 0.8 olarak seçildiğinde ağ daha uygun sonuçlar vermiştir (Tablo 3.23). Bu parametrelerin kullanıldığı ağ bir paket program kullanılarak eğitilmiş ve test edilmiştir.

Tablo 3.23. Ağ Yapısı ve Öğrenme Oranının Deneme Yoluyla Bulunması


Ağ yapısı	Öğrenme oranı	Hata yüzdesi
4-8-1	0.80	0.74
4-8-1	0.60	18.41
4-8-1	0.90	11.58
4-12-1	0.80	8.19
4-12-1	0.60	16.66
4-12-1	0.90	16.95
4-4-1	0.80	4.57
4-4-1	0.60	13.95
4-4-1	0.90	7.11

Ağın test dataları ve test sonuçlarının karşılaştırılması Tablo 3.24’de verilmiştir. Bu ağın iterasyona bağlı hata değişim oranı Şekil 3.31’de verilmiştir.

Tablo 3.24. Yalıtımlı Boru için Oluşturulan Test Seti

Test No	Giriş				Çıkış	
	X ₁	X ₂	X ₃	X ₄	Sayısal sonuç	YSA
1	257	120	10	240	47.3	47.7
2	333	210	15	150	136.8	136.9
3	326	90	22	100	63.9	63.4
4	359	290	13	190	172.7	174


Bu problemde 0.8 öğrenme oranı ve Tablo 3.22’de verilen eğitim setinin uygulanması sonucu yalıtımlı borunun ısı kaybı 175.7 W/m olarak bulunmuştur. Bu problemin çözümü [25] neticesinde bulunan 177 W/m dikkate alınırsa sonuca yeterli hassasiyette yaklaşıldığı görülmüştür [26].



Şekil 3.31. Yalıtımlı Boru için Hazırlanan Sinir Ağının İterasyona Bağlı Hata Değişim Grafiği

3.11. Binadaki Yıllık Isı Kaybı ve Enerji İhtiyacının Yapay Sinir Ağları ile Belirlenmesi

Isı yalıtımı, yapı elemanlarının yalıtılarak ısı kaybının azaltılmasıdır. Isı yalıtımı genel olarak binalarda ve tesisatta kullanılmaktadır. Isı yalıtımının sonuçları, üç boyutuyla ortaya çıkmaktadır. Birincisi, enerji tasarrufu boyutudur. Isı kaybının azalması, kullanılan ısıtıcı malzemeden tasarruf edilmesini sağlamakta yani tesisattaki ilk yatırım masraflarını azaltmaktadır. Bunun yanı sıra daha az yakıt kullanımı nedeniyle parasal tasarruf ortaya çıkmaktadır. İkinci boyut çevre kirliliğinde azalma sağlanması, üçüncü boyut ise ısı konfordur [25].



Şekil 3.32. Uygulamada Kullanılan İki Katlı Bina

Bu çalışmada, Şekil 3.32'deki 3. derece-gün bölgesinde bulunan ve dıştan dışa 9 m eninde, 10 m boyunda, 5.5 m yüksekliğinde, 158.4 m² kullanım alanı olan iki katlı bir konut örneği ele alınarak yıllık ısı kaybı ve yıllık ısıtma enerjisi ihtiyacı hesaplanmıştır. Hesaplamalarda iletim yoluyla gerçekleşen ısı kaybı dikkate alınmıştır.

Tablo 3.25. Uygulamada Kullanılan Binanın Özellikleri


Binadaki Yapı Elemanları	Yapı bileşenleri	Kalınlık
Duvarlar	Dış sıva	0.020 m
	Yatay delikli tuğla	0.190 m
	Isı yalıtım malzemesi	0.060 m
	İç sıva	0.005 m
Döşemeler	Şap	0.030 m
	Isı yalıtım malzemesi	0.080 m
	Tesviye şapı	0.020 m
	Hafif beton	0.100 m
	Blokaj	0.150 m
Tavanlar	Sıva	0.020 m
	Betonarme	0.150 m
	Isı yalıtım malzemesi	0.120 m

Yapay sinir ağları da insanlar gibi örneklerle eğitilirler. Eğitim sırasında yeterli sayıda örneğin kullanılması ile çok iyi sonuçlar elde edilebilmektedir. Bu nedenle çeşitli yükseklikte, ende, boyda ve yalıtım malzemesi kalınlıklarında binada meydana gelecek yıllık ısı kaybı ve enerji ihtiyacının tespiti için eğitim ve test setleri hazırlanmıştır. Eğitim seti ile yapay sinir ağları eğitilmiş daha sonra da eğitim setinde kullanılmamış örneklerden oluşan test seti ile test edilmiştir. Eğitim ve test işlemlerinde kullanılan giriş parametreleri, çıkış parametreleri ve ağı mimarisi Şekil 3.33'de gösterilmiştir.

Yapılan bu çalışmada, ağ mimarisi olarak ileri beslemeli sinir ağı, öğrenme tipi olarak denetimli öğrenme, öğrenme algoritması olarak da, hatayı geriye yayma algoritması kullanılmıştır.

3.11.1. Ağı Eğitilmesi

Şekil 3.33'de görüldüğü gibi giriş tabakasındaki nöron sayısı, yapı yüksekliği, yapı eni, yapı boyu, duvardaki, döşemedeki ve tavandaki yalıtım malzemelerinin kalınlıkları olmak üzere altı adettir. Çıkış tabakasındaki nöron sayısı ise binadaki yıllık ısı kaybı ve yıllık enerji ihtiyacı olmak üzere iki adettir.



Şekil 3.33. Yıllık Isı Kaybı ve Enerji İhtiyacının Tespiti için Oluşturulan Ağ Mimarisi

Gizli tabaka sayısı ve buradaki nöron sayısı deneme yanılma yoluyla bulunmuştur. Tablo 3.26’da da görüldüğü gibi yapılan denemeler sonucunda 10 nöronlu oluşan bir ara katman uygun görülmüş ve öğrenme oranı 0.95 alındığında ağ daha uygun sonuçlar vermiştir. Tablodaki diğer sütunlarda; ağıtasyon sayısı, ağıdan elde edilen çıktı değeri gerçekte sonuçla arasındaki hata yüzdeleri verilmiştir. Gerçek sonuçlara en yakın değeri veren ağ yapısı ve öğrenme oranı dikkate alınmıştır. Yapay sinir ağı eğitilirken aktivasyon fonksiyonu olarak sigmoid tipi bir aktivasyon fonksiyonu kullanılmıştır.

Tablo 3.26. Ağ Yapısı ve Öğrenme Oranının Deneme Yoluyla Bulunması


Ağ yapısı	Öğrenme oranı	İterasyon sayısı	1. Çıkışın hatası	2. Çıkışın hatası
6-10-2	0.95	165	% 0.15	% 0.46
6-10-2	0.60	66	% 0.49	% 0.45
6-10-2	0.75	142	% 0.80	% 2.12
6-6-2	0.80	415	% 0.46	% 0.89
6-6-2	0.50	988	% 0.06	% 2.41
6-6-2	0.75	721	% 0.64	% 2.12
6-8-8-2	0.70	160	% 0.98	% 0.47
6-8-8-2	0.90	129	% 1.01	% 2.40
6-8-8-2	0.60	162	% 0.27	% 1.05
6-12-12-2	0.50	145	% 0.66	% 0.60
6-12-12-2	0.75	96	% 0.20	% 0.76
6-12-12-2	0.90	61	% 1.38	% 0.36

Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 50 adet örnek bulunmaktadır. Eğitim setinde kullanılan örneklerin değeri aralıkları Tablo 3.27’de verilmiştir. Örneklerdeki giriş ve çıkış değeri normalize edilerek ağa sunulmuştur.

Tablo 3.27. Hazırlanan Eğitim Setinde Kullanılan Değerler

Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X ₁	Yapı yüksekliği	4 – 10 m
X ₂	Yapı eni	5 – 15 m
X ₃	Yapı boyu	4 – 13 m
X ₄	Duvardaki yalıtım kalınlığı	0.040 – 0.100 m
X ₅	Döşemedeki yalıtım kalınlığı	0.040 – 0.120 m
X ₆	Tavandaki yalıtım kalınlığı	0.050 – 0.160 m
Y ₁	Yıllık ısı kaybı	130.10 – 264.22 W/K
Y ₂	Yıllık enerji ihtiyacı	9493.32 – 27371.24 kWh

Ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır. Bu öğrenme yöntemi, bütün işleme elemanlarının anlık hatalarını en aza indirmeye çalışır. Bu hata azaltma işlemi, kabul edilebilir doğruluğa ulaşana kadar ağırlıklar devamlı olarak derlenir. Bu parametreler kullanılarak paket programda YSA eğitilir. Bu ağın iterasyona bağlı hata değişimi Şekil 3.34’de verilmiştir.

**Şekil 3.34.** Yapay Sinir Ağının İterasyona Bağlı Hata Değişim Grafiği

3.11.2. Sinir Ağının Test Edilmesi


Yapay sinir ağının eğitimi tamamlandıktan sonra ağın performansını test etmek amacıyla eğitim setindeki örneklerden tamamen farklı örnekler kullanılarak ağ test edilmiştir. Ağın test setinde kullanılan örnekler ve sonuçların karşılaştırılması Tablo 3.28’de verilmiştir.

Tablo 3.28. Hazırlanan Test Seti

Test No	Giriş						Çıkış			
	X ₁ (m)	X ₂ (m)	X ₃ (m)	X ₄ (m)	X ₅ (m)	X ₆ (m)	Sayısal sonuç		YSA	
							Isı kaybı (W/K)	Enerji ihtiyacı (kWh)	Isı kaybı (W/K)	Enerji ihtiyacı (kWh)
1	5.25	9.7	10.3	0.061	0.078	0.111	191.84	16644	191.37	16589
2	6.45	10.7	13.6	0.048	0.102	0.158	269.48	27735	268.35	26467
3	5.3	11.6	13.4	0.074	0.099	0.144	213.87	21424	213.22	21566
4	4.7	10.9	14	0.073	0.098	0.138	202.60	18872	202.00	19010
5	6.6	9.7	12.6	0.085	0.120	0.150	197.81	21293	196.64	20495
6	6.9	9.1	8.6	0.045	0.089	0.108	220.50	19779	220.84	19704
7	5.8	9.6	8.4	0.075	0.083	0.145	164.65	14488	164.33	14437
8	5.5	9.8	10.5	0.057	0.075	0.115	204.07	18113	205.01	18278
9	4.3	10.2	9.8	0.067	0.096	0.113	165.44	13186	165.50	13108
10	7	8.9	8.6	0.045	0.083	0.107	221.24	19826	221.43	19817
11	7.6	8.8	6.9	0.077	0.121	0.132	164.21	15139	164.83	15190
12	4.4	8.6	9.9	0.072	0.067	0.090	162.98	12644	161.84	12432

Yapay sinir ağını eğittikten ve test ettikten sonra; 10 m boyunda, 9 m eninde, 5.5 m yüksekliğindeki binanın duvarına 6 cm, döşemesine 8 cm, tavanına 12 cm kalınlığında yalıtım malzemesi uygulanması göz önüne alınırsa binanın yıllık ısı kaybı 185.49 W/K, yıllık enerji ihtiyacı ise 16152 kWh olarak bulunur. Karakoç [25] ise bu problemin çözümünde yıllık ısı kaybı 185.78 W/K, yıllık enerji ihtiyacı da 16077 kWh olarak elde etmiştir.

3.12. Çatı Döşemesindeki Yoğuşma ve Buharlaşma Miktarlarının YSA ile Tespiti


**Şekil 3.35.** Uygulamada Kullanılan Betonarme Çatı Döşemesi

Yapılan uygulamada, Şekil 3.35’de görülen betonarme bir çatıdaki yoğuşma ve buharlaşma miktarları YSA kullanılarak belirlenmiştir. Yoğuşma miktarının tespiti için geri yayımlı yapay sinir ağı kullanılmıştır. Bu ağda 1 giriş katmanı, 2 ara katman ve 1 çıkış katmanı kullanılmıştır. Girdi katmanında altı işlem elemanı bulunmaktadır:

- Difüzyon dengi hava tabakası iç kalınlığı (betonarme döşeme+bitümlü buhar kesici membran+ polistren partiküler köpük)
- Difüzyon dengi hava tabakası dış kalınlığı (su yalıtımı)

- c) Su buharı iç ortam kısmi basıncı
- d) Su buharı dış ortam kısmi basıncı
- e) İç ve dış ortamın orta noktasındaki basınç
- f) Yoğuşma dönemi periyodu

Her iki ara katmanda da 10 adet yapay nöron kullanılmıştır. Ağın çıkışı ise betonarme çatıda oluşan yoğuşma miktarıdır (Şekil 3.36).



Şekil 3.36. Yoğuşma Kütlesinin Tespiti için Kullanılan Yapay Sinir Ağı

Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 40 adet örnek bulunmaktadır. Eğitim setinde kullanılan örneklerin değer aralıkları Tablo 3.29’da verilmiştir. Örneklerdeki giriş ve çıkış değerleri normalize edilerek ağa sunulmuştur. Yapılan denemeler sonucunda iki ara katman uygun görülmüş ve öğrenme oranı 0.8 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak çift yönlü sigmoid fonksiyonu kullanılmıştır. Ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır. Bu öğrenme yöntemi, bütün işleme elemanlarının anlık hatalarını en aza indirmeye çalışır. Bu hata azaltma işlemi, kabul edilebilir doğruluğa ulaşana kadar ağırlıklar devamlı olarak derlenir. Bu parametreler kullanılarak paket programda YSA eğitilir. Bu ağın iterasyona bağlı hata değişimi Şekil 3.37’de verilmiştir.

Tablo 3.29. Yoğuşma Kütlesi için Hazırlanan Eğitim Setinde Kullanılan Değerler


Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X_1	Hava tabakası iç kalınlığı	25.8–73 m
X_2	Hava tabakası dış kalınlığı	360–850 m
X_3	Su buharı iç ortam kısmi basıncı	1000–1500 Pa
X_4	Su buharı dış ortam kısmi basıncı	155–250 Pa
X_5	İç ve dış ortam arasındaki basınç	200–340 Pa
X_6	Yoğuşma dönemi periyodu	1000–2500 saat
Y	Yoğuşma kütlesi	0.0099–0.0530 Kg/m ²

Ağın eğitimi tamamlandıktan sonra eğitim setindeki örneklerden tamamen farklı değerler kullanılarak ağın performansı test edilmiştir. Test setinde 10 adet örnek kullanılmış ve sonuçlar Tablo 3.30’da karşılaştırılmıştır.

Tablo 3.30. Yoğuşma Kütlesi için Hazırlanan Test Seti

Test No	Giriş						Çıkış	
	X ₁ (mm)	X ₂ (mm)	X ₃ (Pa)	X ₄ (Pa)	X ₅ (Pa)	X ₆ (saat)	Yoğuşma kütlesi (Kg/m ²)	
							Sayısal Sonuç	YSA
1	58.6	492	1410	167	300	1840	0.0229	0.0210
2	33.4	450	1360	180	234	1600	0.0358	0.0352
3	53.0	562	1375	260	271	1350	0.0187	0.0176
4	65.4	512	1450	180	239	1900	0.0233	0.0225
5	27.8	423	1165	145	220	1450	0.0326	0.0313
6	30.2	635	1250	205	335	1275	0.0255	0.0234
7	42.6	714	1300	170	325	2400	0.0362	0.0378
8	55.0	520	1360	175	245	2450	0.0328	0.0349
9	59.8	785	1200	225	350	1850	0.0173	0.0162
10	32.2	487	1090	240	255	2050	0.0353	0.0369

Yapay sinir ağını eğittikten ve test ettikten sonra; problem için verilen değerler ağı sunulursa ağdan elde edilen çıktı değeri 0.0194 Kg/m² olarak bulunur. Bu problemin çözümü [25] sonucunda elde edilen yoğuşma değeri ise 0.019 Kg/m²’dir.




Şekil 3.37. Ağın İterasyona Bağlı Hata Değişim Grafiği

Bu uygulamada da hava tabakası iç kalınlığı 44.8 mm, dış kalınlığı 600 mm, su buharı iç ve dış ortam kısmi basınçları 982 Pa, doymuş su buharı basıncı 2340 Pa, buharlaşma periyodu ise 2160 saat olarak alınarak buharlaşma miktarı tespit edilmiştir. Buharlaşma miktarının tespiti için de 1 giriş katmanı, 1 ara katman ve 1 çıkış katmanı bulunan geri yayımlı yapay sinir ağı kullanılmıştır. Girdi katmanında altı işlem elamanı bulunmaktadır:

- a) Difüzyon dengi hava tabakası iç kalınlığı (betonarme döşeme+bitümlü buhar kesici membran+ polistren partiküler köpük)
- b) Difüzyon dengi hava tabakası dış kalınlığı (su yalıtımı)
- c) Su buharı iç ortam kısmi basıncı
- d) Su buharı dış ortam kısmi basıncı
- e) Doymuş su buharı basıncı
- f) Buharlaşma dönemi periyodu

Gizli katmanda 10 adet yapay nöron kullanılmıştır. Ağın çıkışı ise betonarme çatıda oluşan buharlaşma miktarıdır (Şekil 3.38).



Şekil 3.38. Buharlaşma Kütlesinin Tespiti için Kullanılan Yapay Sinir Ağı

Ağın girdi elemanlarına çeşitli değerler verilerek oluşturulan eğitim setinde 40 adet örnek bulunmaktadır. Ağın eğitim setinde kullanılan örneklerdeki değerler Tablo 3.31’de sunulmuştur. Örneklerdeki giriş ve çıkış değerleri normalize edilerek ağı sunulmuştur. Yapılan denemeler sonucunda iki ara katman uygun görülmüş ve öğrenme oranı 0.75 alındığında ağ daha uygun sonuçlar vermiştir. Aktivasyon fonksiyonu olarak tangent sigmoid fonksiyonu kullanılmıştır. Ağın eğitilmesi için öğrenme tipi olarak danışmanlı öğrenme uygulanmıştır. Bu öğrenme yöntemi, bütün işleme elemanlarının anlık hatalarını en aza indirmeye çalışır. Bu hata azaltma işlemi, kabul edilebilir doğruluğa ulaşana kadar ağırlıklar devamlı olarak derlenir. Bu parametreler kullanılarak bir paket programda YSA eğitilir. Bu ağın iterasyona bağlı hata değişimi Şekil 3.39’da verilmiştir.

Tablo 3.31. Buharlaşma Kütlesi için Hazırlanan Eğitim Setinde Kullanılan Değerler


Giriş ve çıkış parametreleri		Eğitimde kullanılan değerler
X ₁	Hava tabakası iç kalınlığı	25.8–73 m
X ₂	Hava tabakası dış kalınlığı	360–850 m
X ₃	Su buharı iç ortam kısmi basıncı	750–1250 Pa
X ₄	Su buharı dış ortam kısmi basıncı	750–1250 Pa
X ₅	Doymuş su buharı basıncı	2100–2850 Pa
X ₆	Buharlaşma dönemi periyodu	1500–3000 saat
Y	Buharlaşma kütlesi	0.0237–0.1062 Kg/m ²

Ağın eğitimi tamamlandıktan sonra eğitim setindeki örneklerden tamamen farklı değerler kullanılarak ağın performansı test edilmiştir. Test setinde 10 adet örnek kullanılmış ve sonuçlar Tablo 3.32’de karşılaştırılmıştır.

Tablo 3.32. Buharlaşma Kütlesi için Hazırlanan Test Seti

Test No	Giriş						Çıkış	
	X ₁ (mm)	X ₂ (mm)	X ₃ (Pa)	X ₄ (Pa)	X ₅ (Pa)	X ₆ (saat)	Buharlaşma kütlesi (Kg/m ²)	
							Sayısal Sonuç	YSA
1	58.6	492	946	2155	946	2340	0.0360	0.0355
2	21.0	635	780	2750	780	2850	0.1841	0.1830
3	33.4	450	854	2500	854	2100	0.0741	0.0740
4	65.4	512	975	2300	975	2375	0.0361	0.0369
5	27.8	423	1170	2600	1170	1975	0.0721	0.0730
6	30.2	635	1250	2450	1250	1750	0.0485	0.0467
7	55.0	520	880	2375	880	2800	0.0561	0.0548
8	67.4	695	950	2700	950	2650	0.0503	0.0484
9	59.8	785	1200	2750	1200	2300	0.0427	0.0421
10	32.2	487	840	2475	840	2400	0.0866	0.0853

Yapay sinir ağını eğittikten ve test ettikten sonra; problem için verilen değerler ağı sunulursa elde edilen buharlaşma kütlesi 0.0465 Kg/m² olarak bulunur. Bu problemin çözümü [25] sonucunda elde edilen buharlaşma kütlesi ise 0.047 Kg/m²’dir. Gerek test setinden elde edilen sonuçlar ve gerekse problemin gerçek değerlerinden elde edilen sonuçlar göz önüne alındığında ağın yeterli hassasiyette sonuçlar bulduğu görülmüştür [27].

**Şekil 3.39.** Ağın İterasyona Bağlı Hata Değişim Grafiği

4. SONUÇLAR

Yapay sinir ağıları, bilgisayar ortamında, beynin yaptığı işlemleri yapabilen, karar veren, sonuç çıkaran, yetersiz veri durumunda var olan mevcut bilgiden yola çıkarak sonuca ulaşan, sürekli veri girişini kabul eden, öğrenen, hatırlayan bir algoritmadır.

Yapay sinir ağıları, insan beyninin en önemli özelliği olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan gerçekleştirebilen bilgisayar sistemler olduklarından hem yeni gelişmelere neden olmakta hem de nasıl çalıştığı keşfedilemeyen insan beyni hakkında yapılan araştırmalara da önemli katkılar sağlamaktadır.

Yapay sinir ağıları bilgi sınıflama ve bilgi yorumlamanın da içinde bulunduğu çok değişik problemlerin çözümünde kullanılmasının yanı sıra iş hayatı, finans, endüstri, eğitim ve mühendislik alanlarında varolan yöntemlerin yerine veya doğrusal olmayan sistemlerde de başarıyla uygulanmaktadır.

Yapay sinir ağlarının problemlere yaklaşımı insan zekâsı gibi edinilen tecrübeye bağlıdır. Yapay sinir ağıları insanlar gibi örneklerle eğitildikleri için eğitim sırasında yeterli sayıda veri grubunun kullanılması ile çok iyi sonuçlar elde edilmektedir.

Yapılan tez çalışmasında, bir tuğla duvarda yalıtıma ihtiyaç olup olmadığı yapay sinir ağıları kullanılarak analiz edilmiş ve yalıtım gerektiği takdirde yalıtım malzemesinin kalınlığı yine yapay sinir ağıları kullanılarak bulunmuştur. Yine yalıtımlı ve yalıtımsız tuğla duvardaki ve borudaki ısı kayıpları tespit edilmiştir. Borulardaki ısı kayıplarının hesapları oldukça karışık ve zor olduğu için hız ve işlem kolaylığı gibi avantajlarından dolayı YSA tercih edilmiştir. Ayrıca betonarme bir binada meydana gelen ısı kaybı ve buna karşılık olarak binanın ihtiyaç duyduğu enerji miktarının belirlenmesinde de yapay sinir ağı kullanılmıştır. Bir binada meydana gelen ısı kaybını hesaplamak için; ortalama aylık güneş ışınım şiddeti değerleri, aylık ortalama dış sıcaklık değerleri, bina pencerelerinin yönü ve alanları gibi çeşitli detaylar dikkate alınmaktadır. Oysa yapay sinir ağıları ile binanın ısı kaybı, binaya ait yükseklik, en, boy, yalıtım kalınlığı gibi belli özellikler kullanılarak kolaylıkla tahmin edilebilmektedir. Diğer uygulamalarda; betonarme bir çatıda zamanla meydana gelen yoğunlaşma ve buharlaşma kütleleri, silis dumanının çeşitli oranlarda katıldığı beton numunelerinin çarpma dayanımı tespit edilmiştir. Ayrıca kirişlerin donatı alanları ve taşıma gücü momentleri ile tasarım momentleri, kısa konsolların eğilme donatısı ve yatay kuvvete karşılık gelen donatı alanları, ince cidarlı kabukların analizi ve tüp sistemlerin analizi YSA kullanılarak belirlenmiştir. Gerek bu çalışmadan elde edilen sonuçlar gerekse daha önce yapılmış olan çalışmalardan elde edilen sonuçlar ışığında yapay zekânın alt kollarından biri olan yapay sinir ağlarının mühendislik problemlerinde başarılı sonuçlar verdiği

g zlenmiřtir ve yapay sinir aęları m hendislik problemlerinin  z mlerine alternatif bir metot olma yolunda  nemli adımlar atmıřtır.

KAYNAKLAR

- [1] Efe, Ö., Kaynak, O., 2000, Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi Yayınları, İstanbul.
- [2] Vanluchene, R. D., Roufei, S., 1990, Neural Networks in Structural Engineering, Microcomputers in Civil Eng., 207-215.
- [3] Bildik, A. T., 1998, Normal Basınç Dayanımlı Beton Karışımlarının Yapay Sinir Ağları ile Hesaplanması, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, 49s.
- [4] Alexander I., Morton I., 1995, An Introduction To Neural Computing, International Thomson Computer Press.
- [5] Fausett L., 1994, Fundamentals of Neural Networks, Architectures, Algorithms and Applications, Prentice-Hall, Inc., New Jersey.
- [6] Öztemel, E., 2003, Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 232s.
- [7] Harvey, R. L., 1994, Neural Network Principles, Prentice-Hall, Inc., New Jersey.
- [8] Karna, K.N., David, M.B., 1989, An Artificial Neural Networks Tutorial Part:1-Basics,, Neural Networks, Vol:1, No:1, 5-23.
- [9] Bal, C., 2002, Doğru Akım Motorlarının Hız Denetiminde Yapay Sinir Ağlarının Performans Analizi, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, 82s.
- [10] Civalek, Ö., 1998, Nöro-Fuzzy Tekniği ile Dikdörtgen Plakların Analizi, III. Ulusal Hesaplamalı Mekanik Konferansı, 16-18 Kasım, İstanbul, 518-524.
- [11] Koç, M. L., Balas, C. E., Arslan, A., 2004, Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı, İMO Teknik Dergi, 3351-3375.
- [12] <http://www.backpropagation.netfirms.com/ustunlukler1.htm>
- [13] Ülker, M., Civalek, Ö., 2002, Yapay Sinir Ağları ile Eksenel Yüklü Kolonların Burkulma Analizi, Turkish J. Eng. Env. Sci., 117-125.
- [14] Zurada, M.J., 1992, Introduction to Artificial Neural Systems, West Publishing Company, Inc. New York.
- [15] Özmeterler, E., 1989, Yapay Nöral Ağları, Yüksek Lisans Tezi, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.
- [16] Güneş, N., 1997, Geri Yayılmalı Yapay Sinir Ağlarıyla Depreme Maruz Kat Çerçevelerinde Emniyetli Yatay Taşıyıcı Tahmini, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, 57s.
- [17] Elmas, Ç., 2003, Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama), Seçkin Yayıncılık, Ankara, 192s.

- [18] Uguz, H., Kodaz, H., Saraçoğlu, R., İnan O., 2003, Geriye Yayılma Algoritmasındaki Öğrenme Katsayısının Performansa Etkisi, II. Ulusal Meslek Yüksek okulları Sempozyumu, 2003, 1, 1, 0 - 0.
- [19] Megson, T.H.G., 1987, Strength of Materials for Civil Engineers, Londra.
- [20] Hannah J., Hillier M.J., 1995, Applied Mechanics, Pearson Education Limited Edinburgh Gate, Harlow Essex CM20 2JE, England.
- [21] Doğançün, A., 2002, Betonarme Yapıların Hesap ve Tasarımı, Birsen Yayınevi Ltd. Şti., İstanbul.
- [22] Ekinci C. E., Yeğinobalı M. A., 1996, Silis Dumanı Katkılı Betonların Çarpma Dayanımı, TMMOB İnşaat Mühendisleri Odası, 4. Ulusal Beton Kongresi.
- [23] Ekinci, C. E., 2003, Yalıtım Teknikleri, Atlas Yayın Dağıtım, Ankara, 353s.
- [24] Keleşoğlu, Ö., Ekinci C.E. ve Fırat, A. Yalıtım Hesaplarında Yapay Sinir Ağlarının Kullanımı, Sigma Dergisi, 3, 58-66, 2005.
- [25] Karakoç, T.H., Binyıldız, E., Turan, O., 1999, Binalarda ve Tesisatta Isı Yalıtımı, ODE Teknik Yayınları G20.
- [26] Keleşoğlu, Ö., Fırat, A., Tuğla Duvardaki ve Tesisattaki Isı Kaybının Yapay Sinir Ağları İle Belirlenmesi, Fırat Üniversitesi Fen ve Mühendislik Bilimleri Dergisi 18(1), 2006.
- [27] Keleşoğlu, Ö., Fırat, A., Çatı Döşemesinde Meydana Gelen Yoğuşma ve Buharlaşma Kütlelerinin Yapay Sinir Ağları ile Belirlenmesi, Selçuk Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi 21(1), 2006.

ÖZGEÇMİŞ

1982 yılı Elazığ doğumlu olan Tek.Öğret. Adem FIRAT, ilk ve orta öğrenimini Elazığ'da tamamlamıştır. 2003 yılında F.Ü. Teknik Eğitim Fakültesi Yapı Eğitimi Bölümünden mezun olmuştur. Aynı yıl Fırat Üniversitesi Fen Bilimleri Enstitüsü Yapı Eğitimi Anabilim Dalında yüksek lisans çalışmasına başlamıştır. Halen aynı anabilim dalında yüksek lisansa devam etmektedir.