

# MAKİNE ARIZA ZAMANLARININ TAHMİNLENMESİ İÇİN BİR YAPAY SİNİRSEL AĞ MODELİ

Sedat Aydemir, Aydın Sipahioğlu

Osmangazi Üniversitesi, Endüstri Mühendisliği Bölümü, Bademlik, 26030, Eskişehir

## ÖZET

Günümüz işletmelerinde verimliliği arttırmak, kazancın ve rekabet etme yeteneğinin artırılması anlamına geldiği için, önemli bir hedeftir. Bunu sağlamak için çalışanların verimliliğini artırmanın yanı sıra, eldeki makine ve ekipman kullanım yüzdelerinin de artırılması gerekir. İyi bir bakım planlaması ile makine arızaları nedeniyle duruşları azaltmak mümkündür. Öte yandan günde 24 saat üretim yapan makinelerin olası arızalarını önceden tahminlemek, arızaya hazırlıklı olmak ve derhal müdahale etmek açısından büyük avantaj sağlayacaktır. Yalnız arızaya neden olacak çok etken vardır ve bunların arıza oluşumuna etkisini belirlemek de son derece güçtür.

Bu çalışmada, kağıt sektöründe faaliyet gösteren bir firmada, peçete üretimi yapan iki üretim hattı için makine arızaları arasında geçen süreyi tahminleyecek bir çok katmanlı yapay sinirsel ağ (YSA) modeli geliştirilmiştir. Çalışmada ilk olarak geçmiş beş yıla ait üretim ve arıza kayıtları incelenerek, makine arızalarına etki edebilecek faktörler ve düzeyleri belirlenmiştir. Daha sonra YSA'da kullanılacak parametre değerleri ve ağ mimarisi belirlenmiştir. Bu parametreler için uygun değerlerin belirlenmesi deney planlaması çalışması ile yapılmıştır. YSA'nın eğitilmesinden sonra söz konusu makineler için yaklaşık % 90 doğrulukla arıza zamanlarının önceden tahminlenebileceği belirlenmiştir.

**Anahtar Kelimeler:** *Yapay sinir ağı, bakım planlaması.*

## FORECASTING THE MACHINE FAILURE TIMES BY A NEURAL NETWORK MODEL

### ABSTRACT

*Increasing productivity is an important aim because of increasing the ability of profit and competition in today's companies. To get this aim, increasing the usage percentages of existing machine and equipment is necessary besides increasing the productivity of workers. It is possible to decrease ceases because of machine failures with a good maintenance planning. On the other hand, forecasting the 24 hours of working on a day machines' probable failures before they happen will take a great advantage on being prepared and on interfering immediately to these failures. However, there are many factors, which can cause failure and it is very hard to determine these factors' effect on failures become.*

*In this study, there is a multilayered artificial neural network (ANN) model improved for two lines on forecasting time between machine failures on a firm, which is producing in paper sector. In the beginning of this study the last five years data of production and failure examined and the factors that can affect machine failures and their levels determined. After that, parameter values and architecture of network determined, which used by ANN. Suitable values for these parameters have determined using design of experiments. After training ANN, failure times of these machines forecasted beforehand approximately at a value of percentage 90.*

**Keywords:** *Neural networks, maintenance planning.*

### 1. Giriş

Herhangi bir zaman serisinin gelecekte izleyeceği seyri ve alacağı değerleri tahmin edebilmek, biyoloji, fizik, matematik gibi temel bilimlerden, mühendislik, ekonomi, istatistik gibi farklı disiplinleri kapsayan çok geniş bir yelpazede, her geçen gün önemi daha da artan bir gereksinim olmaya devam etmektedir.

Yapay zekâ tekniklerinden genetik algoritmalar ve yapay sinir ağları ile karmaşık ve doğrusal olmayan ilişkiler klasik yöntemlere göre daha iyi analiz edilebilmekte, tahminleme konusunda çok başarılı sonuçlara ulaşılmaktadır. İnsan sinir hücrelerinin öğrenme ve sinyal transferi fonksiyonlarının

modellenmesi gayreti ile ortaya çıkmış olan yapay sinir ağları, doğrusal olmayan veriler arasındaki ilişkileri öğrenebilme yeteneğinden dolayı, benzer teknik ve klasik yöntemlere göre daha başarıyla uygulanmıştır (Hansen, McDonald ve Nelson, 1999).

Verilerin eksik ve/veya aşırı sapma göstermesi durumlarında, klasik yöntemlerle yapılan tahminlerin sonuçları hatalı veya tutarsız olabilir. Yapay Sinir Ağı (YSA) ise verilere tamamen bağlı olmayıp, eksik, kısmen hatalı veya parazit içeren veriyi başarıyla değerlendirebilmektedir. YSA; karmaşık ilişkileri öğrenebilir, genelleleyebilir ve bu sayede daha önce hiç karşılaşmadığı sorulara kabul edilebilir bir hatayla cevap bulabilir. Bu özellikleri ile tahminlemede etkili bir yöntem olarak kullanılmaktadır.

İmalat sektöründe, üretim esnasında problemin tespit edilmesi, sürecin ve üretilen mamullerin kalitesinin devamlı suretle gözlenmesi çalışmalarında sinir ağlarının gerçek zamanlı çalışabilme özelliklerinden oldukça fazla yararlanılmaktadır (Otomasyon, 1996). Bu çalışmada, kağıt sektöründe faaliyet gösteren bir firmada, peçete üretimi yapan iki üretim hattında makine arızaları arasında geçen süreyi tahminleyecek, çok katmanlı bir yapay sinirsel ağ modeli geliştirilmiştir. Bu amaçla öncelikle makine arızalarına etki eden faktörler ve düzeyleri sıralanmıştır. Bu faktörler ışığında geçmiş beş yıla ait veriler derlenmiştir. Derlenen bu veriler kullanılarak, en iyi parametre değerleri ve ağ mimarisi deney tasarımı çalışması ile belirlenen yapay sinir ağı eğitilmiştir.

## 2. Yapay Sinir Ağları

1950'lerde başlayan yapay zeka çalışmaları, 1960'lı yıllarda desen tanıma (Pattern Recognition) problemleri ile ilgilenmeye başlamaları yapay sinirsel ağların temellerinin atılmasını sağlamıştır. Kural tabanlı (Rule Base) sembolleri kullanan uzman sistemlerin yerine desen tanıma problemlerinde kullanılan ilk yapay sinirsel ağ modelleri 1970'lerin başında geliştirilmeye başlanmıştır.

1969'da Marvin Minsky ve Seymour Papert tarafından yayınlanan "Perceptrons" isimli kitapta, tek katmanlı yapay sinirsel ağlarla teorik olarak çözülebileceği ifade edilmiştir. 1970'li yılların başından itibaren, Teuvo Kohonen, Stephen Grossberg, James Anderson, W.S McCulloch ve W.Pitts, D.O. Hebb, B.Widrow ve M. Hoff, D.E. Rumelhart, G.E. Hinton ve J.L. McClelland, J.A. Feldmann gibi birçok bilim adamının çalışmaları sonucunda, çok güçlü sinirsel ağ modelleri oluşturulmuştur. 1986'da sinirsel ağlar ile ilgili 500'ün üzerinde teknik itap ve makale yayınlanmıştır.

1987'den sonra geri yayılım (Backpropagation) algoritmasının (Werbos, Parker, Rumelhart, Hinton ve Williams) geliştirilmesi ile Minsky ve Papert tarafından geliştirilen "Perceptron" sinirsel ağındaki birçok kısıtlama ortadan kalkmış ve çok katmanlı ağlarda sistematik öğrenme sağlanmıştır. Geri yayılım algoritmasının kullanımı ile ses tanıma, el yazısı tanıma, görüntü düzeltme, hedef tanıma gibi birçok uygulama gerçekleştirilmiştir (Çelik, 1996).

Yapay sinir ağları kavramı beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya çıkmış ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin ya da literatürdeki ismiyle nöronların matematiksel olarak modellenmesi üzerinde yoğunlaşmıştır (Lipman, 1987). Bu çalışmaların ortaya çıkardığı bulgular, her bir nöronun komşu nöronlardan bazı bilgiler aldığı ve bu bilgilerin biyolojik nöron dinamiğinin öngördüğü biçimde bir çıktıya dönüştürüldüğü şeklindeydi. Bugün yapay sinir ağları olarak isimlendirilen alan, birçok nöronun belirli biçimlerde bir araya getirilip bir işlevin gerçekleştirilmesi üzerindeki yapısal olduğu kadar matematiksel ve felsefi sorunlara yanıt arayan bir bilim dalı olmuştur (Efe ve Kaynak, 2000).

Yapay sinirsel ağ, proses parametreleri arasındaki ilişkileri, bu ilişkileri gösteren örnekler aracılığıyla öğrenme esasına dayanan sistemlerdir. Öğrenme özelliği belki de araştırmacıların dikkatini yapay sinir ağları üzerine çeken en önemli öğelerden birisidir. Çünkü herhangi bir olay hakkında girdi ve çıktılar arasındaki ilişkiyi elde bulunan mevcut örneklerden genellemeler yaparak ortaya koymak ve bu genelleme ile yeni oluşan veya ortaya çıkan daha önce hiç görülmemiş olayları, önceki örneklerden çağrışım yaparak ilgili olaya çözümler üretebilmek oldukça önemli bir olaydır. Bu özellik yapay sinir ağlarındaki zeki davranışında temelini teşkil eder (Öztemel ve Aydın, 1996).

Yapay sinirsel ağlar, insan beyninin düşünme, problem çözme ve tanıma gibi yeteneklerini sergileyebilecek biçimde geliştirilmiş matematiksel modellerdir. Beynin yapısı ve işlevinden esinlenen bir hesaplama mimarisidir.

Beyin, oldukça karmaşık doğrusal olmayan ve paralel bir işleme sistemidir. Nöronları organize edebilme yeteneği sayesinde hesaplamaları bugün var olan en hızlı bilgisayarlardan daha hızlı olarak gerçekleştirebilmektedir. Yapay sinirsel ağların ilgi çekici niteliklerinden biri de, bağlantı şiddeti/direnci (connection strengths) veya yapısını değiştirerek, kendilerini özel çevre koşullarına adapte edebilme yetenekleridir. Dolayısıyla, sinirsel ağ, tecrübeye dayalı bilgiyi saklama ve kullanımda bunu elverişli

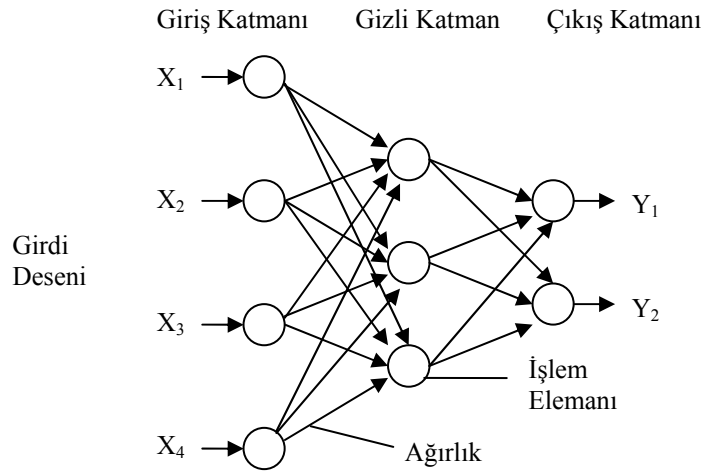
yapmak için doğal bir eğilime sahip tümüyle paralel dağıtılmış bir işlemcidir. İki yönüyle beyne benzemektedir (Özkazanç, 1999). Bunlar:

1. Bilginin ağ tarafından bir öğrenme süreciyle elde edilmesi,
2. Sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantının, bilgi depolamak için kullanılması.

YSA'ların ani değişen değerlerden örnekler olarak, doğrudan doğruya örneklerin birbirleri arasındaki benzer ilişkileri öğrenme yetenekleri vardır. YSA'lar bir konu veya olaydaki verilerden hareketle önceki bilgileri bilmese bile, sonuç çıkarabilir. Çünkü YSA'lar klasik programlama ile çalışmaz. Bir YSA'nın geliştirilmesi bildiğimiz yazılım geliştirmeye benzemez. Zaten aralarındaki en büyük fark, ağların bir iş yapmaları için eğitime ihtiyaç duymalarıdır.

YSA modelleri, problemi etkileyen parametrelerin, sonuca nasıl etkideğini matematiksel olarak saptamak esasına dayanır. Problemi etkileyen parametreler girdi birimleri veya nöronları olarak isimlendirilir. Problemin sonucu ise çıktı birimi veya çıkış nöronudur. Girdi ve çıktı arasında matematiksel ilişki kurulurken, girdideki her bir nöronla çıkış nöronu arasında kurulan bağlantı fonksiyonu için hesaplanan katsayılar o bağlantıların ağırlıkları olarak isimlendirilir. Girdi ve çıktı birimleri arasında kullanılan ara kademeler gizli tabaka olarak isimlendirilir. Çok katmanlı bir YSA Şekil-1'de verilmiştir. Bu durumda girdi nöronları ara kademe nöronlarıyla etkileşir, ara kademe nöronları da çıktı nöronları ile etkileşir.

Öğrenme oranı, keskinlik parametresi ve momentum parametresi değerleri, çıktı nöronunda elde edilen değerle, istenen değer arasında fark olduğu zaman, ağırlık değerlerini güncellemede kullanılan katsayılardır. Örneğin öğrenme oranı küçük seçilirse ağırlıklar küçük aralıklarla güncellenmiş olur, büyük seçilirse büyük aralıklarla güncellenmiş olur. Eşik değeri ise ağırlıkların güncellenmesi sırasında kısır döngüyü engelleyen katsayıdır (Dağlı 1994).



Şekil 1: Çok Katmanlı YSA

### 3. Makine Arızaları Tahmini İçin Bir YSA Modeli

#### 3.1 Problemin Tanımı

Bir makinenin ne zaman arıza yapabileceğinin tahminlenmesi problemi, makine arızalarına etki eden faktörlerin çokluğu ve bunların arıza oluşumuna etkilerini belirlemenin güçlüğü nedeniyle kolay bir problem değildir. Örneğin bu tahminleme bir model yardımı ile gerçekleştirmeye çalışılırsa, çok sayıda parametre ve doğrusal olmayan bir yapıyla karşılaşılır. Böyle bir sistemin modellenmesinde, bir takım kabuller ve sadeleştirmeler yapmadan bütün denklem sistemini çözmek, pratik olarak mümkün olmayabilir.

Bu çalışmadaki amaç, geçmiş verilerden hareketle bir YSA kullanarak makine arızaları arasındaki süreyi tahminlemek ve oluşabilecek arızaları önceden görüp önlemlerini alabilmek, hazırlıklı olabilmektir. Bu sayede arıza duruş süresi azalacaktır. Duruş süresinin azaltılması ise net çalışma zamanını yani verimliliği arttıracaktır.

Çalışma Eskişehir'de kağıt peçete üretimi yapılan bir işletmede gerçekleştirilmiştir. İşletmede S 284 ve S 484 olmak üzere iki peçete hattı bulunmaktadır. Bu iki hat üretim açısından üretim kapasiteleri dışında hiçbir farklılığı bulunmayan, eşdeğerde sayılabilecek hatlardır.

Çalışmada ilk olarak geçmiş beş yıla ait üretim ve arıza kayıtları incelenerek, makine arızalarına etki edebilecek faktörler belirlenmiştir. İşletmede üretilen ürünler arasında desen ve kalınlık farkı bulunmakta, fakat ürün tipi bu faktörlerin yarattığı bütün değişiklikleri tek bir girdi olarak ortaya koymaktadır. Ayrıca veriler incelendiğinde mevsim veya ay farklılığının oluşan arızaların üzerinde bir etkisinin olmadığı gözlenmiştir. Bu bilgiler ışığında oluşturulacak olan YSA'daki girdiler ve çıktı aşağıda açıklanmaya çalışılmıştır.

**Bakım Sıklığı:** S 284 üretim hattında yılda bir kez önleyici bakım yapılırken S 484 üretim hattında üç aylık periyotlarla önleyici bakıma alınmaktadır. Bu hatların yılda kaç kez önleyici bakıma tabii tutulduğu parametremizin düzeyleri olarak belirlenmiştir.

**Vardiya:** Fabrikada çalışma saatleri 7:30–15:30, 15:30–23:30 ve 23:30–7:30 olmak üzere 3 vardiyadır. Bunlar sırasıyla 1.,2. ve 3. vardiya olarak isimlendirilmiştir.

**Makine Ustası:** İki üretim hattında 5 yıl boyunca çalışan makine ustaları tespit edilmiş ve bu makine ustalarından kalifiye olanları ve çalışanların yıllık izinleri, zorunlu haller vb. durumlarda makinelerde çalıştırılan kalifiye olmayan diğer çalışanların kimler olduğu belirlenmiştir. Bu bilgiler ışığında makine ustası girdisi kalifiye ve kalifiye olmayan olmak üzere iki düzeyli incelenmiştir.

**Üretilen Ürün Tipi:** Fabrikada üretilen veya geçmiş 5 yıl içinde üretilmiş olan ürün çeşitleri 20'nin üzerindedir. Makineye takılan bobin büyüklüğü ve kalınlıkları gibi benzerlikler göz önüne alınmış ve bu ürün çeşitliliği ürün tipi olarak gruplanarak düzey sayısı 7'ye indirilmiştir.

**Arızalar Arası Üretim Miktarı:** Arızadan bu yana geçen sürede üretilen ürün miktarı, üretim miktarı olarak alınmıştır. Bu süre içerisinde üretilen ürünlerin çeşitliliğinin fazla olması nedeniyle tek bir eşdeğer birim cinsinden ele alınması gerekmektedir. Bu nedenle bu süreler içerisinde üretilen her ürün cinsinden miktarlar belirlenmiş ve bu miktarlardan hareketle işlenen kâğıt metrajının hesaplanmasına gidilmiştir.

**Bakımdan Arızaya Geçen Süre:** Önleyici bakımdan bu yana geçen süre dakika cinsinden ele alınmıştır.

**Arıza Süresi:** Arıza süresince kaç dakika duruş yaşandığı girdi olarak belirlenmiştir.


**Arızalar Arası Süre:** Tahminlemeye çalışılan değerdir. İki arıza arasında geçen süreyi tanımlar, dakika cinsinden ele alınmıştır.

Problem için parametrelerin ve düzeylerinin belirlenmesinden sonra verilerin derlenmesine geçilmiştir. Geçmiş 5 yıla ait günlük olarak tutulan makine vardiya raporu ve makine bakım raporları incelenerek Tablo 1'de örneği verilen biçimde parametre değerlerine uygun olarak derlenmiştir.

Tablo 1: Derlenen Verilere ait Örnek

No	Arıza tarih/saati	Arıza Süresi (dak.)	Arızalar Arası Süre (dak.)	Arızalar arası Üretim Miktarı (mt)	Makina Ustası	Ürün Tipi	Vardiya	Bakım Sıklığı	Bakımdan Arızaya Geçen Süre(dak)
1	21.10.2002 07:45	45	77.845	670.705.600	1	5	1	1	502.605
2	11.10.2002 05:45	30	14.520	129.902.400	1	2	3	1	488.325
3	3.9.2002 21:55	60	3.235	65.889.600	2	3	2	4	138.115
4	27.8.2002 19:35	60	10.160	118.963.200	2	2	2	4	129.475
5	17.8.2002 09:00	145	14.890	139.017.600	2	2	1	4	114.440
6	13.8.2002 08:20	135	5.665	54.388.800	2	2	1	4	108.640
7	12.8.2002 15:55	60	925	7.905.600	1	2	2	4	107.655
8	11.8.2002 14:25	75	1.455	15.508.800	1	2	1	4	106.125
9	10.8.2002 11:00	280	88.655	633.684.200	1	5	1	1	396.660
10	9.8.2002 12:40	140	1.200	18.812.400	1	5	1	1	395.320
11	8.8.2002 03:55	60	1.905	25.034.400	1	5	3	1	393.360
12	7.8.2002 16:40	130	545	23.899.800	1	5	2	1	392.685
13	7.8.2002 05:20	60	620	16.104.000	1	5	3	1	392.005

Derlenen veriler YSA'da çıktı olarak kullanılacak arızalar arasındaki süre değerlerine göre incelendiğinde, 200'den fazla durumda arızalar arası süresi 25.000 dakikanın altında gerçekleştiği belirlenmiştir. Eldeki verilerin arızalar arasındaki süreler göre dağılımı Şekil 2'de verilmiştir.



Şekil 2: Verilerin Arızalar Arası Süreye Göre Dağılımı

Bir yapay sinir ağında kullanılacak olan test verilerinin seçimi o ağın performansını doğrudan etkilemektedir. Eğer test verileri tutarlı seçilmezse, kurulacak ağı eğitimi çok zaman alabilir ve daha kötüsü test verilerinin ana kütle temsil etmemesi sebebiyle sonuçlar tutarlı olmayabilir. Bu nedenle test verilerinin seçiminde Şekil 2’de gözlenen dağılıma uygun davranılmaya çalışılmıştır.

Çalışmada veriler normalleştirilerek kullanılmıştır. Öğrenme metodu olarak geri yayılım algoritması, öğrenme fonksiyonu olarak sigmoid (lojistik) fonksiyon ve Qwiknet 2.23 yazılımı kullanılmıştır. Normalleştirme işlemi her veri tipinin en büyük değeri seçilerek ve diğer veriler bu değere bölünerek gerçekleştirilmiştir. Normalleştirme işleminin tüm verilere uygulanması sebebiyle herhangi bir veri kaybı durumu mevcut değildir.

### 3.2 Parametrelerin ve Ağ Mimarisinin Deney Tasarımı ile Belirlenmesi

Deney tasarımı, değişik koşullarda bağımsız değişkenlerin bağımlı değişkeni nasıl etkilediğini araştırmak için gerekli tasarımları hazırlayan ve çözümlenmelerini veren bir tekniktir. Denetim altındaki bir deneyde denetlenemeyen değişkenliğin ölçüsü, deneysel yanığı olarak nitelendirilir. Deney tasarımındaki amaç ise söz konusu deneysel yanığın en küçüklenmesidir.

Bu çalışmada iki farklı deney tasarımı ile hem sinirsel ağ parametrelerinin uygun değerleri araştırılmış hem de uygun ağ mimarisi seçilmek istenmiştir. Uygulanan tasarımlar aşağıda verilmiştir. İki tasarım sonucunda toplam üç tane uygun parametre değerleri ile çalışan sinir ağı belirlenmiş, yapılan karşılaştırmalar sonucunda üstün olduğu tespit edilen yapı seçilmiştir. YSA parametrelerinin uygun değerlerinin belirlenmesine ilişkin deneyler Qwiknet V2.23 programı ile gerçekleştirilmiştir.

#### Tasarım 1

Bu tasarımda performans karakteristiği, YSA’nın test aşamasında türettiği ortalama hata değeri olarak belirlenmiştir. YSA’larda böyle bir performans karakteristiği öğrenme katsayısı, momentum terimi, gizli katman işlem elemanı sayısı, eğitim algoritması, aktivasyon fonksiyonu, gizli katman sayısı ve hata düzeyi faktörlerinin bir fonksiyonudur. Bu faktörlerden bazıları sabit tutulmuş ve her deney 500.000 ardışık olacak şekilde faktörler üçe indirgenmiştir. Bu tasarımda dikkate alınan faktörler ve düzeyleri Tablo-2’de verilmiştir.

Tablo 2: Tasarım 1 için YSA Performansına Etki Eden Faktörler ve Düzeyleri

Faktör	1. Düzey	2. Düzey	3. Düzey
A. Öğrenme Katsayısı	0.4	0.6	0.8
B. Momentum Terimi	0.2	0.4	0.6
C. Gizli Katman İşlem Elemanı Sayısı	10	30	50

Yapılan deneyler sonucunda öğrenme katsayısının 0.4, momentum teriminin 0.2 ve işlem elemanı sayısının 30 seçildiğinde ortalama tahmin hatası % 17.716 olarak gerçekleştiği gözlenmiştir.

#### Tasarım 2

Bu tasarımda YSA’nın test aşamasında türettiği ortalama hata değeri yanı sıra, katman sayısı da artırılarak ağ mimarisinin de etkisi araştırılmak istenmiştir. Burada gizli katman sayısı iki olarak belirlenmiş ve bu bilgilere göre tasarımda dikkate alınan faktörler ve düzeyleri Tablo 3’de verilmiştir.


Elde edilen gözlem değerleri incelendiğinde büyük ağ modellerinde tahminleme hatasının azaldığı ortaya çıkmıştır. Çok katmanlı ağ mimarisinin gizli katmanlarının kabaca bir piramide benzetilmesi, öğrenme ve test performansını olumlu yönde etkilemektedir.

Tablo 3: Tasarım 2 için YSA Performansına Etki Eden Faktörler ve Düzeyleri

Faktör	1. Düzey	2. Düzey	3. Düzey
A. Öğrenme Katsayısı	0.4	0.6	0.8
B. Momentum Terimi	0.2	0.4	0.6
C. 1.Gizli Katman İşlem Elemanı Sayısı	10	30	50
D. 2.Gizli Katman İşlem Elemanı Sayısı	5	15	30

Yapılan deneyler sonucunda 1. tasarımda bulunan % 17.716 ortalama tahmin hatası % 9.907'ye indirgenmiştir. Bu sonuçlara göre öğrenme katsayısı 0.4, momentum terimi 0.2, gizli katman sayısı 2, 1. katman işlem elemanı sayısı, 50 ve 2. katman işlem elemanı sayısı, 30 olarak belirlenmiştir.

Tablo 4: Geliştirilen Yapay Sinir Ağı Mimarisi



### 3.3 Geliştirilen YSA ile Elde Edilen Sonuçlar

İşletmeye ait 5 yıllık verilerin derlenmesiyle 274 satırdan oluşan öğrenme verisi elde edilmiş, bunlardan 55 satırlık bilgi, test verisi olarak ayrılmıştır. 55 satırlık bilgi daha önce belirlenen arızalar arası sürelerin dağılımına uygun olarak belirlenmiştir. Geliştirilen 2 gizli katmanlı YSA modeline belirlenen veriler öğretildikten sonra, seçilen test verileri için tahmin yaptırılmıştır. Bu süreçte geri yayılım algoritması, sigmoid fonksiyon ve deney planlamasıyla belirlenen parametre değerleri kullanılmıştır. Uygulanan algoritma şöyle özetlenebilir.

#### Algoritma

Adım 1: Başlangıç girdi verilerini (Bakım sıklığı, vardiya türü, usta tipi, ürün tipi, ürün miktarı, bakımdan arızaya geçiş süresi ve arıza süresi) ve çıktı verilerini (arızalar arası geçen süre) oku.

- Adım 2: Ağırlık matrisini ve hata oranlarını belirle (Matris, program tarafından -1 ile 1 arasında rassal değerler olacak şekilde belirlenir).
- Adım 3: Her bir satır için çıktı değerini hesapla.
- Adım 4: Beklenen çıktı değeriyle, hesaplanan çıktı değerlerini karşılaştırarak gerçekleşen hatayı hesapla. Hata istenen sınır değerlerindeyse dur, değilse 5. adıma git.
- Adım 5: Geri yayılım ile ağırlıkları güncelle.
- Adım 6: Yeni çıktı değerlerini hesaplayarak 4. adıma dön.

Test verileriyle yapılan öğrenme kontrolü sonucunda, önerilen ağ tarafından, arızalar arası sürenin %100'e çok yakın değerlerde doğru olarak tahmin edildiği belirlenmiştir. İzleyen aşamada söz konusu iki üretim hattında gerçekleşen ve YSA'nın eğitiminde kullanılmayan son 5 aya ait arıza verileri derlenerek, ağın arızalar arası süreyi belirlemedeki performansı araştırılmıştır. Derlenen (daha önce eğitimde kullanılmamış) 18 yeni veri programa test verisi olarak girildiğinde, YSA'nın arızalar arası süreyi % 90 oranında doğru olarak tahminlediği gözlenmiştir. Aşağıda son 5 aya ilişkin derlenen verilerin programın verdiği çıktı ile gerçekleşen değerlerin karşılaştırması yapılmıştır. Bu karşılaştırmadan da görüleceği üzere arızalar arası süreyi küçük bir hata ile hesaplamaktadır. Tahminlenen değerlerin dakika cinsinden olması işletmede vardiya usulü çalıştığı için tahminlemedeki sapmanın önemini azalmaktadır.

Tablo 4: Hesaplanan ve Gerçekleşen Çıktı (Normalleştirilmiş ve Gerçek Değerler)

Output1	Target1	Output1	Target1
0.142259	0.134990	18378.44	17439.4
0.016410	0.011500	2120.008	1839.735
0.143621	0.056430	18554.4	7290.19
0.044866	0.044100	5796.239	5313.48
0.072057	0.053250	9309.044	6879.37
0.078880	0.075590	10190,51	9765,47
0.058180	0.040330	7516.274	5210.23

Tablo 4'deki verileri incelendiğinde en büyük hata değerinin 3. satırdaki 18.554 ve 7290 değerleri arasında olduğu görülmektedir. Aradaki süre 11. 264 dakikadır. Bu da yaklaşık 187 saattir, yani 7.8 güne denk gelmektedir. Kısaca en çok 1 haftalık hata ile arıza zamanı tahmin edilebilmektedir. Öte yandan diğer değerler incelendiğinde, arızanın gerçekleşeceği vardiyanın veya günün doğru olarak tahmin edilebildiği görülmektedir.

#### 4. Sonuç ve Öneriler

Günümüzde işletmelerde farklı bakım planlaması stratejileri uygulanmasına rağmen, bu çalışmada belirtilen türden çeşitli faktörlerin etkisiyle arızalar oluşmakta ve hazırlıksız olmak nedeniyle çalışma zamanında önemli kayıplar oluşmaktadır.

Bu çalışmada önerilen yöntem ile arızaların gerçekleşeceği zamanları tahmin etmek ve buna hazırlıklı olarak hızlı çözümler üretmek mümkündür. Bu da elbette verimliliği arttıracaktır. Önerilen yöntemle işletmede nasıl bir bakım planlamasının uygun olacağı da analiz edilebilecektir. Hatta bu çalışmada incelenen girdiler olan vardiya türü, usta tipi, ürün tipi, arızadan sonra yapılan üretim miktarı, bakımdan arızaya geçiş süresi ve arıza süresinin de problemi nasıl etkilediğini araştırmak ve bunlara göre önlemler almak mümkün görünmektedir. Böylece sistemi etkileyen parametreler iyileştirilecek ve muhtemelen arızalar arası sürenin uzaması sağlanacaktır. Bu çalışmayla YSA ile geçmiş verileri kullanarak gerçekleşmesi beklenen arızalar için, makine arızaları arasındaki süreyi tahminlemenin mümkün olacağı gösterilmiştir.

Öte yandan çalışmadaki bir diğer yenilik, YSA tasarımında hem kullanılacak parametre değerlerinin, hem de ağ mimarisinin deney planlaması teknikleriyle belirlenebileceğinin gösterilmesidir. Çalışmada öğrenme oranının, momentum terimi, gizli katman sayısı ve gizli katman işlem elemanı sayısının belirlenen düzeylerinin tamamı denenmiş ve öğrenme katsayısının 0.4, momentum teriminin 0.2, gizli katman sayısının 2 olması gerektiği ve işlem elemanı sayılarının sırasıyla 50 ve 30 alındığında daha iyi sonuçlar elde edildiği gözlenmiştir. Her bir deney 500.000 ardıştırmaya kadar devam ettirilmiştir. Bu tür bir problemde YSA mimarisinin piramide benzer azalan yapıda olmasının daha iyi sonuçlar

verdiği görülmüştür. Bunun yanı sıra ağ mimarisinde gizli katman sayısının artırılmasının da sonuçları olumlu yönde etkilediği gözlenmiştir. Ancak hepsinden önemlisi bu çalışmayla karmaşık bir veri grubundan yararlanılarak, arızalar arası sürenin yaklaşık %90 doğrulukla tahmin edilebileceği gösterilmiştir.

Daha detaylı bir deney planlaması ile daha iyi sonuçlar verecek bir YSA geliştirmek mümkündür. Ayrıca deney planlamasında da tam faktöryel çalışma yapmak yerine, Taguchi yaklaşımlarının kullanılmasıyla daha fazla seçeneğin gözden geçirilmesi mümkün olabilir. Geliştirilen yaklaşımın bir pilot çalışma olarak kabul edilip işletme geneline uyarlanması halinde, bakım planlamasının düzenlenmesinde başarı ile kullanılabileceği de açıktır.

## KAYNAKLAR

**Çelik., O. N.,** Küresel Grafitli Dökme Demirlerde Cu, Ni ve Mo Alaşım Elementlerinin Ostemperleme Sonucu Beynit Oluşumuna Etkisinin İncelenmesi ve Sonuçların Yapay Sinirsel Ağ Sistemleriyle Değerlendirilmesi, Doktora Tezi. Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir. 142s. 1996.

**Çelik., O. N., Sipahioğlu A.** Forecasting the Effect of Heat Treatment Conditions and Alloy Elements to the Formation of Bainite and Hardness by a Neural Network Model. ASME Intelligent Engineering Systems through Artificial Neural Networks. Ed. Dağlı. et al.. Vol.10. pp. 863-868. 2000.

**Dağlı. C.H.** Artificial Neural Networks for Intelligent Manufacturing. *Transaction of Operational Research*. 6. 1-25. 1994.

**Efe. M. Ö., Kaynak. O.** Yapay Sinir Ağları ve Uygulamaları. Boğaziçi Üniversitesi. 2000.

**Hansen. J. V., Mc Donald. J. B., Nelson. R. D.** Time Series Prediction with Genetic Algorithm Designed Neural Networks: An Empirical Comparison with Modern Statistical Models. *Computational Intelligence*. 15:3. 171-184. 1999.

**Jain. A. K., Mao J.** Artificial Neural Networks: A Tutorial. *IEEE*. 9162. 31-44. 1996.

**Lippman. R.** An Introduction to Computing With Neural Nets.. *IEEE ASSP Magazine*. 4-22. 1987.

**M. Ham. Fredric. Kostanic. Ivica.** Principles of Neurocomputing For Science and Engineering. New York. Mc Graw Hill. 2001.

**Özkazanç. Ü.** Atölye Tipi Üretim Ortamında İşlerin Çizelgelenmesi İçin Yapay Sinir Ağı Yaklaşımı. Yüksek Lisans Tezi. Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir. 29-52. 1999.

**Öztemel. E.** Bilgisayarda Öğrenme ve Yapay Sinir Ağları. *Otomasyon*. 134-140. Mart 1996.

**Öztemel. E., Aydın. M.E.** Yapay Sinir Ağlarına Dayalı Deneysel Tasarım Metodu ve Bir Endüstriyel Uygulama. *J. Of Engineering and Enviroment Sciences*. Tubitak. Sayı:20. 73-78. 1996.