

**T.C.  
BALIKESİR ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**



**TRANSFORMATÖR ÜRETİMİNDE ÜRETİM  
ZAMANLARININ YAPAY SİNİR AĞLARI İLE TAHMİNİ  
İÇİN BİR ÇALIŞMA**

**YÜKSEK LİSANS TEZİ**

**ÖMÜR KARADEMİR**

**BALIKESİR, EKİM - 2014**

**T.C.  
BALIKESİR ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**



**TRANSFORMATÖR ÜRETİMİNDE ÜRETİM  
ZAMANLARININ YAPAY SİNİR AĞLARI İLE TAHMİNİ  
İÇİN BİR ÇALIŞMA**

**YÜKSEK LİSANS TEZİ**

**ÖMÜR KARADEMİR**

**BALIKESİR, EKİM - 2014**

## KABUL VE ONAY SAYFASI

**Ömür KARADEMİR** tarafından hazırlanan “**TRANSFORMATÖR ÜRETİMİNDE ÜRETİM ZAMANLARININ YAPAY SİNİR AĞLARI İLE TAHMİNİ İÇİN BİR ÇALIŞMA**” adlı tez çalışmasının savunma sınavı ..15.10.2014..... tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği / oy çokluğu ile Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı Yüksek Lisans Tezi olarak kabul edilmiştir.

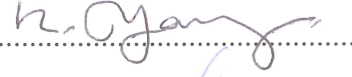
Jüri Üyeleri

İmza

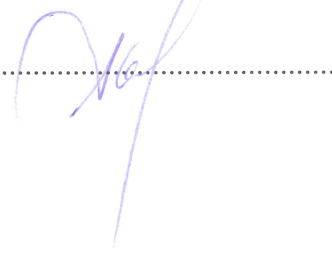
Danışman  
Yrd. Doç. Dr. Aslan Deniz KARAOĞLAN



Üye  
Prof.Dr.Ramazan YAMAN



Üye  
Doç.Dr. Ali ORAL



Jüri üyeleri tarafından kabul edilmiş olan bu tez BAÜ Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Fen Bilimleri Enstitüsü Müdürü

Prof. Dr. Cihan ÖZGÜR

.....

## ÖZET

# TRANSFORMATÖR ÜRETİMİNDE ÜRETİM ZAMANLARININ YAPAY SINIR AĞLARI İLE TAHMİNİ İÇİN BİR ÇALIŞMA

YÜKSEK LİSANS TEZİ  
ÖMÜR KARADEMİR

BALIKESİR ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ  
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

(TEZ DANIŞMANI: YRD. DOÇ.DR. ASLAN DENİZ KARAOĞLAN)

BALIKESİR, EKİM - 2014

Yüksek cirolarla ancak düşük kar marjları ile yoğun bir rekabet ortamında faaliyet gösteren elektromekanik sektöründe, alınan siparişlerin ön maliyetlerinin düşük varyansla doğru bir şekilde hesaplanması gerçekçi bir fiyat teklifi verebilmek ve rekabet edebilmek için zorunludur. Transformatör üretimi siparişe göre gerçekleştirilmekle birlikte düşük miktarlarda ve birbirinden farklı çok çeşitte üretim yapılmaktadır.

Emek yoğun çalışılan sektörde bitmiş ürünün önemli maliyet kalemlerinden biri işçilik maliyetidir. Gerçek işçilik maliyetleri ürün tamamlandığında ortaya çıkmaktayken müşteriye fiyat teklifi ise üretim gerçekleşmeden önce sipariş aşamasında verilmektedir. Firmanın bu konuda izlediği yol, geçmişte üretilen siparişlerden yola çıkarak hesaplanan tahmini işçilik sürelerini dikkate alarak son fiyat teklifini verme şeklindedir. Ancak verilen fiyat teklifinin gerçekleşen maliyetin altında kalması durumunda firma zarar ederken, yüksek kalması durumunda ise siparişi kaçırma tehlikesi söz konusu olabilmektedir. Bu nedenle işçilik zamanının düşük varyansla doğru bir şekilde tahmin edilmesi gerekmektedir.

Bu çalışmada, alınan yağlı tip trafo siparişinin teknik şartnamede yer alan gücü, gerilimi vb girdilerine karşılık, üretim zamanları değerleri kullanılarak ileri beslemeli geri yayımlı yapay sinir ağı eğitilmiş ve daha önceden üretimi yapılmamış siparişlerde dahil olmak üzere yeni alınan siparişlerin üretim zamanları düşük bir sapmayla tahmin edilmiştir.

**ANAHTAR KELİMELEER:** Yapay sinir ağları, zaman tahmini, geri beslemeli ağlar,  
çok katmanlı algılayıcı

## **ABSTRACT**

**A STUDY ON PREDICTION OF MANUFACTURING TIMES IN  
TRANSFORMER PRODUCTION INDUSTRY BY USING ARTIFICIAL  
NEURAL NETWORKS  
MSC THESIS  
ÖMÜR KARADEMİR  
BALIKESİR UNIVERSITY INSTITUTE OF SCIENCE  
INDUSTRIAL ENGINEERING**

**(SUPERVISOR: ASSIST. PROF. DR ASLAN DENİZ KARAOĞLAN )**

**BALIKESİR, OCTOBER 2014**

In the electromechanic sector which rustles with high returns but low profits, it is a must to calculate the orders anticipated cost for giving a realistic price offer and rivaling. Production of transformes is done according to the orders, with low quantity and wide range.

In this labor intensice sector, one of the most important cost item of the finished product is labor cost. The real labor cost forms after the product is finished, but price offer is given to the customer during the order level. The path which firm follows about this subject is; giving the final cost order according to the projected labor hours coming from the produced orders before. But if the order is under the cost, firm suffers a loss; if its higher than the cost, its possible to miss the order. Therefore, labor time should be estimated correctly with low variance.

In this study, considering the oil type transformer orders inputs like power, voltage etc., using the production time, a feedforward backpropagation artificial neural network is educated and not only the unfinished passed orders but also the new taken ones production times are estimated with low variance.

**KEYWORDS:** Artificial neural networks, time estimation, backpropagation, multi layer network

# İÇİNDEKİLER

## Sayfa

ÖZET.....	i
ABSTRACT .....	ii
İÇİNDEKİLER .....	iii
ŞEKİL LİSTESİ.....	iv
TABLO LİSTESİ .....	v
KISALTMALAR LİSTESİ.....	vi
ÖNSÖZ.....	viii
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI .....	4
3. YAPAY SİNİR AĞLARI.....	10
3.1 Yapay Sinir Ağlarına Giriş .....	10
3.1.1 Yapay Sinir Ağlarının Genel Tanımı ve Özellikleri .....	10
3.1.2 Yapay Sinir Ağlarının Tarihçesi .....	12
3.2 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları.....	13
3.2.1 Yapay Sinir Hücreleri ve Çalışma İlkesi .....	13
3.2.2 Yapay Sinir Ağları ve Çalışma İlkesi.....	16
3.3 Yapay Sinir Ağı Modelleri .....	19
3.4 Çok Katmanlı Algılayıcılar.....	21
4. YAPAY SİNİR AĞLARI İLE GÜÇ TRAFOLARI ÜRETİM SÜRELERİNİN TAHMİNİ.....	27
4.1 Mevcut Durum ve Problemin Tanımı.....	27
4.2 Trafonun Tanımı, Özellikleri ve Üretim Süreci.....	29
4.3 Eğitim Seti .....	33
4.3.1 Girdi ve Çıktı Verilerinin Belirlenmesi.....	33
4.3.2 Girdi ve Çıktıların Ölçeklendirilmesi.....	35
4.4 Tasarlanan ağı yapısı .....	36
5. SONUÇ VE ÖNERİLER .....	43
6. KAYNAKLAR.....	45
7. EKLER.....	49

## ŞEKİL LİSTESİ

	<b><u>Sayfa</u></b>
Şekil 3.1: Biyolojik sinir hücresi ve bileşenleri	14
Şekil 3.2: Yapay sinir hücresi	15
Şekil 3.3: Yapay sinir ağı modeli	17
Şekil 3.4: YSA girdi çıktı ilişkisi	18
Şekil 4.1: Yağlı trafo	30
Şekil 4.2: Yağlı trafo akış şeması	31
Şekil 4.3: Yağlı trafo üretim süreci	32
Şekil 4.4: Tasarlanan yapay sinir ağı modeli	37
Şekil 4.5: Gerçek süreler ile YSA ile tahmin edilen sürelerin karşılaştırması	40

## TABLO LİSTESİ

	<b><u>Sayfa</u></b>
<b>Tablo 4.1:</b> Girdilerin minimum ve maksimum değer aralıkları	35
<b>Tablo 4.2:</b> Örnek veri tablosu	36
<b>Tablo 4.3:</b> Test verileri	38
<b>Tablo 4.4:</b> Denenen yapay sinir ağıları	39
<b>Tablo 4.5:</b> Girdi katmanı ile 1. ara katman arasındaki ağırlık değerleri	41
<b>Tablo 4.6:</b> 1. ara katman ile 2. ara katman arasındaki ağırlık değerleri	41
<b>Tablo 4.7:</b> 2. ara katman ile çıktı katmanı arasındaki ağırlık değerleri	42
<b>Tablo 5.1:</b> Test verileri	43



## KISALTMALAR LİSTESİ

- ADRES** : Adaptif çıktı oranı üstel düzeltme modeli (adaptive response rate exponential smoothing)
- ANN** : Yapay sinir ağı (artificial neural network)
- BPN** : Geri yayımlı yapay sinir ağları (back propagation network)
- CR** : Kritik miktar kuralı (critical ration)
- ÇKA** : Çok katmanlı algılayıcı
- DD** : İşin tamamlanma zamanı (due date)
- DTW** : Dinamik TWK kuralı (dynamic total work content method)
- DPPW** : Dinamik işlem + bekleme kuralı (dynamic processing plus waiting)
- FT** : İşin akış zamanı (flowtime)
- FF-BPN** : İleri beslemeli geri yayımlı yapay sinir ağı (feed forward back propagation artificial neural network)
- GA** : Genetic algoritma (genetic algorithm)
- LDP** : Son veri noktası (last data point)
- MAD** : Ortalama mutlak sapma (mean absolute deviation)
- MAL** : Ortalama mutlak gecikme (mean absolute lateness)
- MAPE** : Ortalama mutlak yüzdesel akış zamanı tahmin hatası (mean absolute percent flowtime prediction error)
- MSE** : Ortalama hata kare (mean square error)
- MPE** : Ortalama yüzdesel hata (mean percent error)
- MSL** : Ortalama kare gecikme (mean square lateness)
- MT** : Ortalama gecikme (mean tardiness)
- OSLK** : İşlem gevşekliği kuralı (operation slack)
- PCA** : Ana bileşenler analizi (Principle component analysis)
- RMSE** : Kök ortalama kare akış zamanı tahmin hatası (root mean square

flowtime prediction error)

**SDL** : Gecikmenin standart sapması (standard deviation of lateness)

**TWK** : Toplam iş içeriği kuralı (the total work content)

**YSA** : Yapay sinir ağları

## ÖNSÖZ

Bu tez çalışmasının araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteğini esirgemeyip yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren, bilgi ve tecrübelerinden önemli ölçüde yararlandığım sayın Yrd. Doç. Dr. Aslan Deniz KARAOĞLAN' a sonsuz teşekkürlerimi sunarım.

Yüksek lisansım süresince desteklerini esirgemeyen BEST A.Ş yetkililerine ve test işlemlerinin yapılmasında yardımlarını esirgemeyen, çalışma arkadaşım Esen BİRLİK'e teşekkür ederim.

Sevgili eşime ve çocuklarıma manevi hiçbir yardımı esirgemedен yanımda oldukları için tüm kalbimle teşekkür ederim.

Ömür KARADEMİR

Ekim - 2014

# 1. GİRİŞ

Bir işletmenin faaliyetlerini etkin bir şekilde yürütebilmesi için standart zamanlara önemli ölçüde ihtiyacı vardır. Üretim planlarının hazırlanması, kısa ve uzun vadeli tahminler, ön maliyet hesabı, ücretlendirme konuları başta olmak üzere işletme içinde yürütülen tüm faaliyetlerde standart zamanlara dayanmadan yapılacak işlerin tutarlı ve faydalı olması mümkün değildir. Buna karşın işleri düşük maliyetle ölçebilecek yöntem ve araçların henüz geliştirilemediği bir gerçektir.

Standart sürelerin tespiti aşamasında yaşanan zorluklar, zaman etüdü gibi doğrudan sahada yapılan ölçüm yöntemlerine ek olarak alternatif zaman belirleme yöntemlerini de beraberinde getirmiştir. Fakat bu yöntemlerin tüm işletmelerde ürün yada yarımamülün standart süresinin tespitinde kullanılabilecek yöntemler olmadığı ve çeşitli yetersizlikleri olduğu da bir gerçektir.

İşte bu nedenlerden dolayı zamanların yapay zeka (makine öğrenmesi) ile tahmininde büyük kazançlar sağlanabileceği açıktır. Yapay zekanın en çok kullanılan yöntemlerinden biride yapay sinir ağlarıdır (YSA). YSA'lar günümüzde pek çok sektörde uygulama alanı bulmuştur.

Transformator sektörü, üretimin siparişe göre yapıldığı ve rekabetin çok yoğun olduğu bir sektördür. Gelen siparişlerin teslim zamanı ve maliyetinin doğru bir şekilde belirlenmesi, sektördeki diğer işletmelere karşı büyük bir rekabet avantajı sağlamaktadır. Bu tez de ele alınan temel problem, teklif aşamasındaki siparişlerin üretim maliyetinin doğru hesaplanabilmesi için işin toplam süresinin gerçekçi olarak tahmin edilebilmesidir.

Firmada müşteri isteklerine göre aynı anda birçok farklı tasarıma sahip transformatör üretimi yapılmakla birlikte her bir farklı tasarımın işlem ve taşıma süreleri farklı olasılık dağılımlarına sahip rassal değişkenlerdir. Ayrıca transformatörlerin mevcut atölyedeki iş yoğunluğuna, stoklardaki hammadde durumuna, makina arıza ve fire oranlarına bağlı olarak bekleme süreleri de yine

rassal deęişkendir. Tüm bu nedenlerden dolayı ele alınan sistem stokastik ve dinamik bir yapıya sahiptir ve ele alınan problemin analitik yöntemlerle çözümü çok güçtür.

İşlerin tamamlanma zamanının tahmin edilmesine ilişkin olarak literatürde yer alan çalışmalar genellikle işlem süreleri, çevrim zamanı ortalaması, varyanslar, iş yükü, boşta beklemeler, kuyrukta bekleyen iş sayısı, ortalama kuyrukta bekleme süreleri vb. iş veya atölye ile ilgili karakteristikleri dikkate alarak işin tamamlanma süresinin tahmini üzerine yoğunlaşmıştır. Daha önceden üretilen ürünler için geçmiş verilerden yararlanarak yapılacak çalışmalar ile işin tamamlanma zamanı tahmin edilebilir. Ancak işletmenin daha önceden üretmedięi bir ürüne ait sipariş geldiğinde bu siparişe ait üretim süresinin tespit edilmesi firma için büyük bir sorundur. Çünkü gelen siparişlerin çok büyük bir bölümü ya ilk defa yapılan bir üründür ya da eskiden üretilmiş olan siparişlerin ürün özelliklerinin müşteri isteęine göre revize edilmiş halleridir. Ayrıca müşterinin siparişinde istedięi ürünün üretimi için kullanılacak malzeme cinsi, üretim teknięi ve benzeri ürün özelliklerinin farklı kombinasyonları ve birbirleri ile etkileşimleri, işlerin işlem sürelerinin ve dolayısıyla buna baęlı tamamlanma zamanlarının birbirine göre oldukça farklı olmasına yol açmaktadır.

Mevcut yapıda yeni sipariş için sunulacak tekliflerde daha önce yapılan ürünler için elde edilen zamanlar deęerlendirilerek bir zaman tahmini ve bunun sonucunda ön maliyet çıkarılmaya çalışılmaktadır. Geçmişe yönelik insan deneyimi ile yapılan bu analizler her zaman doęru ve güvenilir bilgi vermemekte ve çok zaman almaktadır. Eksik kalan bu ilişkileri bünyesinde insan bilinçaltı gibi barındıran bir yöntem kullanılması önemlidir. Yapay sinir aęları çözülmesi zor olan problemlere hata oranı düşük ve hızlı sonuçlar vermektedir.

Çalışmada süreye etkisi olan trafonun teknik özellikleri ve üretimden elde edilen imalat sürelerinden faydalanılarak yapay sinir aęları eğitilmiştir. Bu eğitimler sonucunda firmanın gelen yeni siparişler için işin tamamlanma süresini hesaplayan bir aę tasarlanmıştır.

Bu çalışmanın amacı; eski üretim sürelerinden faydalanarak süre tahmini yapan firmalar için alternatif bir tahmin yöntemi geliştirmektir.

Literatürde yayınlanmış olan çalışmalardan bazıları siparişlerin sisteme varışlarını, beklemelerini, ortalama işlem sürelerini dikkate alarak belirli varsayımlar

altında üretim sistemini modellemiş, daha sonra bu modelleri kullanarak atölyeye veya işe ilişkin karakteristikler için zaman tahminleri yapmışlardır. Ancak belirli varsayımlar altında yapılan bu çalışmalarda sunulmuş olan yöntem, bu projeye konu olan firmada uygulanabilir değildir. Bunun nedeni literatürde yapılan çalışmalarda işlem sürelerinin veya dağılımının bilindiği varsayılmaktadır. Firmada ise binlerce ürün çeşidine ait zaman verilerinin çok büyük bir bölümü elde yoktur ve belli başlı ürünler hariç gelen bir siparişin tekrar aynı özelliklerde gelme olasılığının düşük olmasından dolayı bu siparişlere ait zaman verilerinin dağılımını çıkartacak kadar veriye ulaşmakta mümkün değildir. Ayrıca bir transformatörün üretiminin aylarla ölçüldüğünü göz önüne alırsak zaman etüdü çalışmalarının tüm ürünler için yapılması da pratikte mümkün değildir.

Bu tezin özgün yanı ve literatürde daha önceden sunulmuş çalışmalardan farkı, işlem sürelerinin kesin değeri veya olasılık dağılımı bilinmediğinde, daha önceden hiç üretilmemiş bir ürün için işlem süresinin ne olacağının siparişin kendine has özelliklerinden yola çıkarak tahmin edilecek olmasıdır. Başka bir deyişle bu tez ile; mevcut üretimlerin ürün özellikleri ile bu ürünleri üretmek için gerekli işlem süreleri arasındaki ilişkinin yapay sinir ağları ile modellenmesi, sonrasında bu modeller kullanılarak sistemde yukarıda sayılan ürün özelliği kombinasyonlarından daha önce hiç üretilmemiş bir ürün geldiğinde bunun işlem süresinin ne olacağının tahmin edilmesi, tahmin edilen işlem süresi ve diğer bilgileri kullanan ve atölyenin dinamik durumunu dikkate alan programlar ile işin teslim tarihi hesabının ve işin tamamlanma zamanı hesabının yapılması hedeflenmektedir.

Tezin ikinci bölümünde, daha önce yapılan çalışmalar hakkında araştırma yapılmış ve kısa bilgiler verilmiştir. Üçüncü bölümde, yapay sinir ağları ile ilgili bilgiler ele alınmaktadır. Dördüncü bölümde ise tezin uygulama bölümüne yer verilmiştir. Son olarak sonuç ve öneriler bölümünde ise çalışmadan elde edilen sonuçlar değerlendirilmektedir.

## 2. LİTERATÜR TARAMASI

Üretim sistemleri incelendiğinde üretilen ürünlerin aynı üretim rotasını izlemesi veya atölye tipi üretimde olduğu gibi her ürünün farklı rotalar izlemesi söz konusu olabilir. Her ürünün farklı rotalar izlemesi durumunda üretim süreleri, kuyrukta bekleme süreleri, kuyrukta bekleyen iş sayıları v.b. farklılık gösterecektir. Kapasite kullanım yüzdeleri atölye tipi üretimde genellikle diğer tip üretime göre düşüktür. Daha da ötesinde ürün ve ürün miktarındaki arz, talebin yapısı ve çeşitliliğine göre dönem dönem farklılık göstermektedir. Bu nedenle birim maliyetleri düşürmek için kapasite kullanım oranının artırılması yaygın olarak hedeflense de, siparişe göre ve emek yoğun çalışılan üretim sistemlerinde işçilik sürelerinin birim maliyetler üzerindeki etkisinin dikkate alınması birim maliyetleri düşürmede önem arz etmektedir.

İyileştirilmesi hedeflenen üretim sürecinde, her bir sipariş müşteri talebine göre farklılık göstermekte ve siparişlerin pek çoğu daha önceden üretilen ürünlerden kısmen veya tamamen farklı özellikler göstermektedir. Bu da üretim aşamaları için gerekli işçilik sürelerinin değişken olması anlamına gelmektedir. İşçilik sürelerinin ürünün maliyetine doğrudan etkisi olmasından dolayı; işin gerçekleşen tamamlanma zamanının, olması gerekenden daha az tahmin edilmesi durumunda müşteriye verilen fiyat teklifine işçilik maliyetinin eksik yansıtılması ve firmanın zarar etmesi, tam tersi durumda ise müşteriye yüksek fiyat teklifi verilmesi ve siparişi alamama tehlikesi ortaya çıkmaktadır. Her iki durumda da firmanın zararı söz konusu olduğundan dolayı, her sipariş alındığında fiyat teklifi vermeden önce üretim sürecinin ne kadar zaman alacağına yüksek doğrulukta, düşük sapmayla ve hızlı bir biçimde tahmininin yapılabilmesi önem arz etmektedir.

Literatürde pek çok çalışmada işlerin tamamlanma zamanı sabit kabul edilip bu süre içerisinde üretimin nasıl arttırılacağı araştırılmışken, yine literatürde bu varsayımı dikkate almadan işlerin tamamlanma zamanının tahmin edilmesine ilişkin olarak çok sayıda çalışmaya rastlanmaktadır. Söz konusu tahmin tekniklerden en yaygın kullanılanları klasik çizelgeleme veya matematiksel optimizasyon yöntemleridir (analitik yöntemler). Bu yöntemler belirli kısıt fonksiyonlarını

kullanarak, önceden belirlenmiş amaç fonksiyonlarını sağlayacak şekilde işleri çizelgelemekte veya süreç içerisindeki değişkenlerin optimum parametre değerlerinin ne olması gerektiğini hesaplamaya çalışmaktadır. Ancak müşteri isteklerindeki en ufak değişiklikler veya özel istekler, bu yöntemlerin yapılan varsayımlara aşırı duyarlı olmasından dolayı doğru şekilde çözüm aşamasına dahil edilememektedir. Aynı şekilde uygulamaya geçilen çözümün, çözüm geliştirme aşamasında yapılan varsayımların gerçekleşmemesi durumunda istenilen hedef çıktıyı sağlayamadığı sıkça gözlenmektedir. Amaç ve kısıt fonksiyonlarına bağlı bu yöntemler, problemin boyutu büyüdükçe çok daha karmaşık ve yoğun matematiksel hesap gerektirmektedir. Çözümü istenen problem belli bir büyüklüğe ulaştıktan sonra çözüm imkânsız hale gelir. Bu durumlarda, optimum sonucu vermese de yaklaşık optimum sonuç veren sezgisel (heuristic) yöntemler kullanılır. Yapay zeka optimizasyon algoritmaları da sezgisel yöntemler içinde yaygın olarak kullanılan yöntemlerdendir. İşlerin tamamlanma zamanının tahmininde yapay sinir ağları, genetik algoritma gibi pek çok yapay zeka tekniği kullanılabilir.

İşin tamamlanma zamanının yapay sinir ağları ile tahmini ile ilgili olarak literatürde göze çarpan çalışmalar Arizono ve diğerleri (1992) ile başlamaktadır. Yazarlar yapay sinir ağlarını kullanarak işin akış zamanının tahmini ve minimizasyonu üzerinde çalışmışlardır. Hopfield ağına genişletilmiş bir hali olan Gaussian machine modelini kullanmışlardır. Girdi değişkenleri olarak işin sırası, işin işlem süresi, iş sırada beklerken işin hazırlık süresi, işin başlangıç zamanı, gerçekleşen akış zamanı değerlerini kullanmışlardır (Arizono, I., Yamamoto, A. and Ohta, H. 1992).

Lee ve Kim (1993), Hill ve Remus (1994), Statake (1994) yapay sinir ağları ile çizelgeleme üzerine çalışmışlar ve composite neural network (birleşik yapay sinir ağı), ileri beslemeli geri yayımlı ağlar (feed forward back propagation neural network), Hopfield ağı, Boltzmann makine mekanizması (Boltzmann machine mechanism) gibi farklı yapay sinir ağı modellerinden yararlanmışlardır. Yazarlar, işin çevrim zamanını minimize etme ve buna bağlı olarak en erken teslim zamanını bulma üzerine uğraşmışlardır.

Philipoom ve diğerleri (1994) nonlinear regresyon modelleri ile yapay sinir ağlarını işin tamamlanma zamanını tahmin performanslarına göre



karşılaştırmışlardır. Performans ölçütü olarak; tamamlanma zamanını tahmini, ortalama mutlak sapma (mean absolute deviation (MAD)), gecikmenin standart sapması (standard deviation of lateness (SDL)) ölçütlerini kullanmışlardır (Philipoom, P., Rees, R. and Wiegman L. 1994).

Sabuncuoğlu ve Gürgün (1996) algoritmik ve yapay sinir ağı (Hopfield ağı) yaklaşımlarını birleştirmiş ve tek makinalı atölye sisteminde işler, iş sıraları ve makinaları girdi olarak kullanarak; ortalama gecikme (mean tardiness) ve en kısa çevrim zamanını (minimum makespan) tespit etme üzerine çalışmışlardır (Sabuncuoğlu, İ. ve Gürgün B. 1996).

Chen ve Muraki (1997) geri yayımlı (back-propagation) yapay sinir ağlarından yararlanarak işletmenin önceki durumunu on-line olarak güncelleyen ve iş çizelgelemesi ve tamamlanma zamanı tahmini yapan ağ geliştirme üzerinde çalışmışlardır (Chen, W. and Muraki, M. 1997).

Raaymakers ve Weijters (2003) regresyon modellerinden ve yapay sinir ağlarından yararlanarak çevrim zamanlarının ve buradan hareketle işin tamamlanma zamanının tahmini üzerine çalışmalar yaparak bu iki yöntemin performansını kıyaslamıştır. Raaymakers ve Weijters'e göre regresyon modellerinin avantajı girdilerle çıktılar arasındaki ilişkiyi matematiksel olarak modelleyebilmesi olarak tanımlanırken, yapay sinir ağlarının avantajı ise girdilerle çıktılar arasındaki complex nonlinear ilişkileri otomatik olarak algılayabilmesidir. Ancak bilindiği gibi yapay sinir ağları kullanıcıya bir matematiksel denklem sunmamaktadır. Yazarlar deney tasarımında tam faktöriyel tasarımdan yararlanmışlardır. Modellemede girdi değişkenleri olarak özdeş makine sayısı (number of identical resources), ortalama işlem adım sayısı (the average number of processing steps), ortalama çakışma (the average overlap), işlem sürelerinin standart sapması (the standard deviation of processing times), iş yükü dengesi (workload balance) değişkenlerini kullanmışlar ve bunlara bağlı olarak işin tamamlanma zamanını tahmin etmişlerdir (Raaymakers, W. H. M., and Weijters, A. J. M. M. 2003).

Hsu ve Sha (2004), yapay sinir ağlarından yararlanarak işin tamamlanma zamanını tahmin etmeye çalışmışlardır. Yapay sinir ağlarının eğitiminde simülasyon ve istatistiksel tekniklerden yararlanmışlardır. Önerilen yöntem farklı dağıtım

kuralları (dispatching rules) ve sipariş alma/verme (order review/release) kurallarının farklı kombinasyonları için iyi sonuçlar vermiştir. Performans ölçütü olarak işin tamamlanma zamanı tahmini ve gecikme oranı (tardiness rate) değerlerini almışlardır (Hsu, S.Y. and Sha, D.Y. 2004).

Li ve diğerleri (2005 ve 2007) paralel kaynakların ortalama sayısı, her iş için ortalama işlem adımı sayısı, işlem adımlarındaki ortalama çakışma sayısı, iş yükü dengesi ve üretim süresindeki çevrim zamanı standart sapma girdilerine karşılık işin çevrim zamanının buna bağlı olarak da tamamlanma zamanının tahmin edilmesinde geri yayımlı yapay sinir ağları ile genetik algoritmanın birleşiminden oluşan bir yöntem önermişlerdir. Performans ölçütü olarak beklenenle gözlenen süreler arasındaki farkın ortalama hata kare (mean squared error - mse) değeri kullanılmıştır (Li S., Li Y., Liu Y., et al. 2005, 2007).

Alenezi ve diğerleri (2008) support vector regression modelinden yararlanarak çok kaynaklı çok işli bir üretim sisteminde gerçek zamanlı iş akış zamanı tahmininde bulunmuşlardır. Performans ölçütü olarak ortalama mutlak yüzdesel akış zamanı tahmin hatasını (mean absolute percent flowtime prediction error – MAPE), kök ortalama kare akış zamanı tahmin hatasını (root mean square flowtime prediction error – RMSE) kullanmışlar ve ileri beslemeli yapay sinir ağı ile kıyaslamışlardır. Girdi olarak her bir işin her bir makinadaki kuyruk uzunluğu ve işin sisteme vardığında sistemin durumunu ve işin gerçek zamanlı akış zamanını almışlardır (Alenezi, A., Moses, S. A. and Trafalis, T.B. (2008).

Patil (2008) işin tamamlanma zamanının tahmininde yapay sinir ağlarından faydalanmıştır. Patil, yapay sinir ağının yapısının (topolojisinin) belirlenmesinde genetik algoritma kullanmıştır. Belirli bir iş için gerekli operasyon sayısı, işlem süreleri toplamı, bu işin işlem göreceği rotada kuyrukta bekleyen iş sayısı, aynı rotada makinalarda beklenen kuyrukta bekleme sayısı ve işlem süresi gibi genel iş ve atölye karakteristikleriyle; işlere veya atölyeye ait bazı özel karakteristikler (örneğin i. işin belirli bazı operasyonlarının işlem süreleri) girdi olarak kullanılmış ve genetik algoritma tabanlı yapay sinir ağı ile işlerin tamamlanma zamanı tahmin edilmeye çalışılmıştır (Patil, R. J. 2008).

Zhu ve diğeri (2008) işin tamamlanma zamanının tahmin edilmesinde Petri-net simülasyonundan yararlanarak farklı üretim kaynakları ve ürün tipleri için yapay sinir ağlarını eğitmiş ve başarılı sonuçlar almışlardır (Zhu, H. P., Zhan, H. H., Liu, F.M., et al. 2008).

Baykasoğlu ve diğeri (2008) önermiş oldukları iki istatistiksel tabanlı tamamlanma zamanı tahmin yöntemini (adaptif çıktı oranı üstel düzeltme modeli (adaptive response rate exponential smoothing (*ADRES*) model) ve son veri noktası modeli (last data point - *LDP* model)) geleneksel tahmin yöntemleri (dinamik TWK kuralı (dynamic total work content - *DTWK*) ve dinamik işlem + bekleme kuralı (dynamic process plus waiting - *DPPW*)) ile kıyaslamışlardır. Bu amaçla simülasyondan yararlanarak veri türetilmiş ve ortalama mutlak yüzdesel hata (mean absolute percent error - *MAPE*), ortalama yüzdesel hata (mean percent error - *MPE*) ve ortalama gecikme (mean tardiness - *MT*) performans çıktıları açısından kıyaslamalar yapılmıştır. Girdi olarak her bir istasyondaki makine sayısı, her bir işin rotası, rotalara göre işlerin işlem süreleri, siparişlerin istasyonlar arası taşınma süreleri alınmıştır (Baykasoğlu, A., Göçken, M. ve Unutmaz, Z.D. 2008).

Baykasoğlu ve Gökçen (2009), gen tanımlı programlama (gene expression programming) adını verdikleri yöntemleri ile işin tamamlanma zamanını tahmin etmişler ve pek çok geleneksel tahmin yöntemleri ile önerdikleri bu yeni yöntemin performansını simülasyon modelleri kurarak elde ettikleri verileri kullanarak karşılıklı olarak kıyaslamışlardır. Bu çalışmada, kıyaslamada performans çıktısı olarak *MAPE*, *MPE* ve *MT* alınmıştır. Girdi olarak ise gelen her bir iş için gerekli toplam operasyon sayısı, iş sistemden ayrılana kadar sistemde var olan işlerin sayısı, bir işin rotası boyunca gerek duyduğu operasyonların ortalama işlem süresi, bir işin rotası boyunca ortalama kuyrukta bekleme süresi alınmıştır (Baykasoğlu, A. ve Gökçen, M. 2009).

Alpay ve Yüzügüllü (2009) kaçırılan tamamlanma zamanını dikkate almışlar; *MAL* ve *MSL* performans ölçütlerini çıktı olarak alarak kendi önerdikleri yöntemin (critical ratio+operation slack *CR+OSLK*) performansını çok makinalı atölye tipi üretim yapan sistem için ortaya koymuşlardır. Alpay ve Yüzügüllü girdi olarak işle ilgili faktörlerden her bir işin işlem sürelerini ve operasyon sayılarını alırken, atölye ile ilgili girdi faktörleri olarak ayrı ayrı her bir iş atölyeye vardığında ve atölyeden

ayrıldığında, bu işlerin herbirinin rotalarındaki ve rotaları dışındaki makinelerdeki ve kuyruklardaki toplam iş sayısı ile en son tamamlanan üç işin tahmin edilen ortalama akış zamanlarını almışlardır. Performans kıyaslamasında tam faktöriyel tasarımdan yararlanarak girdilerin farklı kombinasyonlarını simülasyon yoluyla türetip denemişlerdir (Alpay, Ş. ve Yüzügüllü N. 2009).

Asadzadeh ve diğerleri (2011) üretim sistemi içerisinde işlerin tamamlanma zamanının tahmininde yapay sinir ağları, bulanık regresyon ve geleneksel regresyon yöntemlerini içeren bir tahmin algoritması önermişlerdir. Bu algoritma ile ilk olarak öğretmenli öğrenme algoritması ile eğitilen çok katmanlı yapay sinir ağı ile işin tamamlanma zamanı tahmin edilmiş ve bu ağın tahminleri bulanık ve geleneksel regresyon modeli tahminleri ile ortalama mutlak yüzdelik hata açısından karşılaştırılmıştır. Bu yöntem sinirsel-bulanık regresyon algoritması adını vermişlerdir (Asadzadeh, S.M., Azadeh, A. and Ziaefar, A. 2011).

Chen ve Wang (2013) ana bileşenler analizi (principle component analysis - PCA), bulanık mantık (fuzzy logic) ve geri yayımlı yapay sinir ağlarından (back propagation network - BPN) yararlanarak işlerin çevrim zamanını tahmin etmişlerdir (Chen, T. and Wang, Y.C. 2013). Literatür taramasının özeti EK A' da verilmiştir.

### **3. YAPAY SİNİR AĞLARI**

#### **3.1 Yapay Sinir Ağlarına Giriş**

Bu bölümde yapay sinir ağları hakkında genel bilgiler verilmiştir. İlk olarak yapay sinir ağlarının genel tanımı ve özellikleri anlatılmış, ardından yapay sinir ağlarının tarihsel gelişimine yer verilmiştir. Devamında ise yapay sinir ağlarının yapısı ve temel elemanları anlatılmıştır. Son olarak yapay sinir ağı modellerinden kısaca bahsedilerek, çok katmanlı algılayıcılar hakkında detaylı bilgiler verilmiştir.

##### **3.1.1 Yapay Sinir Ağlarının Genel Tanımı ve Özellikleri**

Yapay sinir ağları (YSA), insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri otomatik olarak gerçekleştirebilmek amacı ile geliştirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek çok zor veya mümkün değildir. Bu nedenle yapay sinir ağlarının programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş bir bilgisayar bilim dalı olduğundan bahsedilebilir (Öztemel, E. 2003). Diğer bir tanıma göre yapay sinir ağları; insan beyni düşünülerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanıp her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapıları; bir başka ifadeyle, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır (Elmas, Ç. 2003).

Yapay sinir ağları, gerçekleştirilmiş örneklerden elde edilen verileri kullanarak olayları öğrenebilen ve çevreden gelen olaylara karşı nasıl tepkiler üreteceğini belirleyebilen bilgisayar sistemleridir. İnsan beyninin özelliklerine benzer şekilde öğrenme, ilişkilendirme, genelleme, sınıflandırma, özellik belirleme ve optimizasyon gibi konularda uygulanmakta ve başarılı sonuçlar sağlamaktadırlar. Örneklerden elde ettikleri ile kendi deneyimlerini oluşturarak benzer konularda benzer kararları verirler. Bu özellikleri ile günümüzde birçok probleme çözüm

üretebilecek yeteneğe sahiptirler. Yapay sinir ağının en temel görevi ise ağa gösterilen girdi setine karşı uygun olabilecek bir çıktı seti belirlemektir (Öztemel, E. 2003).

Yapay sinir ağlarının kısaca özelliklerinden bahsetmek gerekirse; yapay sinir ağları olayları öğrenerek benzer durumlar karşısında benzer kararlar vermeye çalışarak makine öğrenmesi gerçekleştirirler. Klasik programlama ve yapay zeka yöntemlerinin uygulandığı bilgi işleme yöntemlerinden farklı bilgi işleme yöntemi vardır.

Dağıtık belleğe sahiptirler ve bilgiler diğer programlardan farklı olarak veri tabanında değil ağın bağlantıları ile ölçülmekte ve bu bağlantılarda saklanmaktadır. Örnekleri kullanarak öğrenirler ve bu sayede olay hakkında genelleme yapabilecek yeteneğe kavuşturulurlar. Ağın güvenle çalıştırılması için önce eğitilip test edilmesi gerekmektedir. Ağ kendisine gösterilen örneklerden yararlanarak hiç görmediği örnekler için de bilgiler üretebilir.

Bilgiye dayalı çözümlerden daha çok algılamaya yönelik bilgileri işlemede kullanılırlar. İlişkilendirme ve sınıflandırma yapabilirler. Kendi kendini organize etme ve öğrenebilme yetenekleri vardır. Geleneksel sistemler eksik bilgi olduğunda çalışmaz ancak yapay sinir ağları eğitimden sonra eksik bilgiler ile çalışabilir ve sonuç üretebilirler. Ayrıca eksik bilgilerle çalışabilme yetenekleri sayesinde hatalara karşı toleranslıdırlar.

Yapay sinir ağları belirsizlikler altında öğrendikleri ile karar verebilmektedirler. Sadece nümerik bilgiler ile çalıştıkları için sembolik ifadelerle gösterilen bilgilerin nümerik hale dönüştürülmesi gerekmektedir (Öztemel, E. 2003).

Yapay sinir ağlarının birçok avantajlı durumunun yanında bazı dezavantajları da mevcuttur. Bunlar kısaca;

Yapay sinir ağlarında ağın nasıl oluşturulacağı ile ilgili kuralların olmaması önemli bir dezavantajdır. Probleme uygun ağın yapısı çoğunlukla deneme yanılma yolu ile yapılmaktadır. Eğer probleme uygun ağ oluşturulamazsa çözülmesi mümkün olan problemin çözülememesi veya daha iyi sonuca ulaşamamasına neden olabilir. Yapay sinir ağları kabul edilebilir sonuçlar üretirler ve hiçbir zaman optimum

çözümü garanti etmezler. Ayrıca öğrenme katsayısı, katman sayısı vb parametrelerin belirlenmesinde de bir kural yoktur. Bunların belirlenmesi kullanıcının tecrübesine kalmaktadır. Ağın eğitiminin ne zaman biteceğine dair geliştirilmiş bir yöntem yoktur. Ağın örnekler üzerindeki hatasının belli bir değerin altına düşmesi yeterli görülmektedir. Ancak en iyi eğitimin gerçekleştiği söylenememektedir. En önemli sorunlardan biri ise ağın davranışlarının açıklanamamasıdır. Başarılı olarak ağın eğitiminden sonra bunun nasıl elde edildiği konusunda bilgiye ulaşmak mümkün değildir (Öztemel, E. 2003).

### 3.1.2 Yapay Sinir Ağlarının Tarihçesi

İlk yapay sinir ağı modeli 1943 yılında, insan beyninin hesaplama yeteneğinden yola çıkarak elektrik devreleriyle basit bir sinir ağını modelleyen sinir hekimi Warren McCulloch ile matematikçi Walter Pitts tarafından gerçekleştirilmiştir. 1949 yılında Hebb “Organization of Behavior” isimli kitabında öğrenme ile ilgili temel teoriyi ele almış ve öğrenebilen ve uyum sağlayabilen sinir ağı modeli için temel oluşturacak Hebb kuralını ortaya koymuştur. Hebb kuralı sinir ağının bağlantı sayısı değiştirilebilirse öğrenebileceğini öngörmektedir. 1950’li yıllardan sonra Hebb kuralından faydalanarak birçok araştırmacı yapay sinir ağının hesaplama gücünü artırıcı çalışmalarda bulunmuştur.

1957 yılında, beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar sırasında ortaya çıkan tek katlı eğitilebilen ve tek çıkışa sahip olan yapay sinir ağı Perceptron’un Frank Rosenblatt tarafından gerçekleştirilmesiyle yapay sinir ağı alanındaki gelişmeler hızlanmıştır. 1959 yılında, Bernard Widrow ve Marcian Hoff ADALINE ve MADALINE diye adlandırdıkları ağ modellerini geliştirmişlerdir. 1969 yılında Minsky ve Papert Perceptronun XOR problemini çözemediğini ispatlayarak tek katmanlı ağlardaki birçok sorunu ortadan kaldıran iki katmanlı ileri beslemeli ağların kullanılabileceğini ileri sürmüşlerdir. Fakat gizli katmanların ağırlıklarının nasıl değiştirileceğine bir çözüm bulamamışlardır. Rumelhart ve arkadaşları geri yayılım yöntemi ile bu soruna çözüm getirmiştir.

Seksenli yıllar yapay sinir ağlarının gelişiminin hızla ilerlediği yıllar olmuştur. Hopfield 1982 yılında ağların önemli sınıflarının matematik temellerini

üretmiştir. John Hopfield yapay sinir ağlarının genelleştirilebileceği ve geleneksel bilgisayar programlama ile çözülmesi zor olan problemlere çözüm üretilebileceğini göstermiştir. 1984 de Kohenen danışmansız öğrenme ağlarını geliştirmiştir. 1986 da Rumelhart ve McClelland karmaşık ve çok katmanlı ağlar için geriye yayımlı öğrenme algoritmasını geliştirmiştir. 1987 yılında sinir ağlarını konu alan ilk uluslararası konferans düzenlenmiştir. Günümüzde tüm dünyada yapay sinir ağları ile ilgili birçok araştırma-geliştirme ve uygulama faaliyetleri yoğun ve başarılı bir şekilde devam etmektedir (Elmas, Ç. 2003).

## **3.2 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları**

### **3.2.1 Yapay Sinir Hücresi ve Çalışma İlkesi**

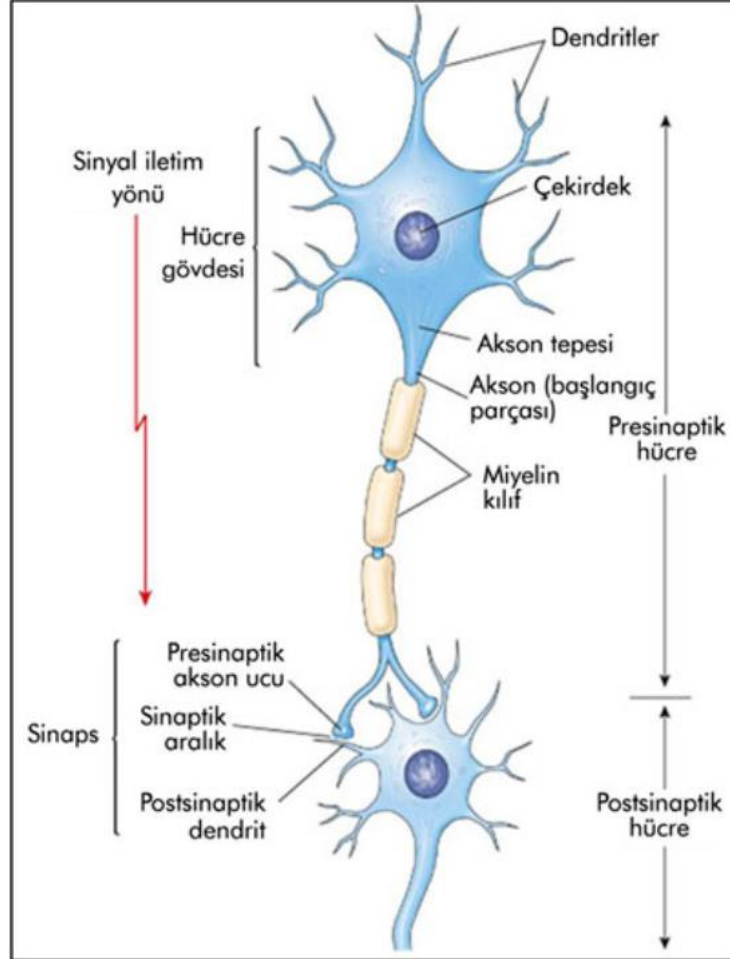
Yapay sinir ağları biyolojik sistemden esinlenerek geliştirilmiştir. Bu nedenle önce kısaca biyolojik sinir hücrelerinden bahsedilecektir.

Biyolojik sinir ağları beynimizde bulunan çok sayıda sinir hücresinin birleşimidir. Sinir ağı milyarlarca sinir hücresinin bir araya gelmesi ile oluşur ve birbirleri ile bağlanarak işlevlerini yerine getirirler. İnsan beyninde  $10^{10}$  adet sinir hücresi ve bunlarında  $6 \times 10^3$ ' ten daha çok sayıda bağlantısı olduğu bilinmektedir. Biyolojik sinir ağlarının performansları çok yüksek ve karmaşık olayları işleyebilecek güçtedir. Yapay sinir ağları ile bu performansın bilgisayar üzerine aktarımı amaçlanmıştır (Öztemel, E. 2003).

Şekil 3.1'de görüldüğü gibi, bir sinir hücresinin temel elemanları hücre gövdesi, dendrit ve akson'dur. Sinir hücresine diğer sinir hücrelerinden gelen uyarımlar, dendritler aracılığıyla hücre gövdesine taşınır ve hücre içi kararlılık halinin bozulmasıyla oluşan bir kimyasal süreç içerisinde diğer hücelere aksonlarla iletilir. Uyarımların diğer sinir hücrelerine taşınabilmesinde akson uçları ile dendritler arasındaki sinaptik boşluklar rol oynar. Sinaptik boşluk içinde yer alan "sinaptik kesecikler", gelen uyarımların diğer hücelere dendritler aracılığıyla geçmesini sağlayan elemanlardır. Hücelere gelen uyarımlarla uyumlu olarak hüceler arasındaki mevcut sinaptik ilişkilerin değişimi veya hüceler arasında yeni



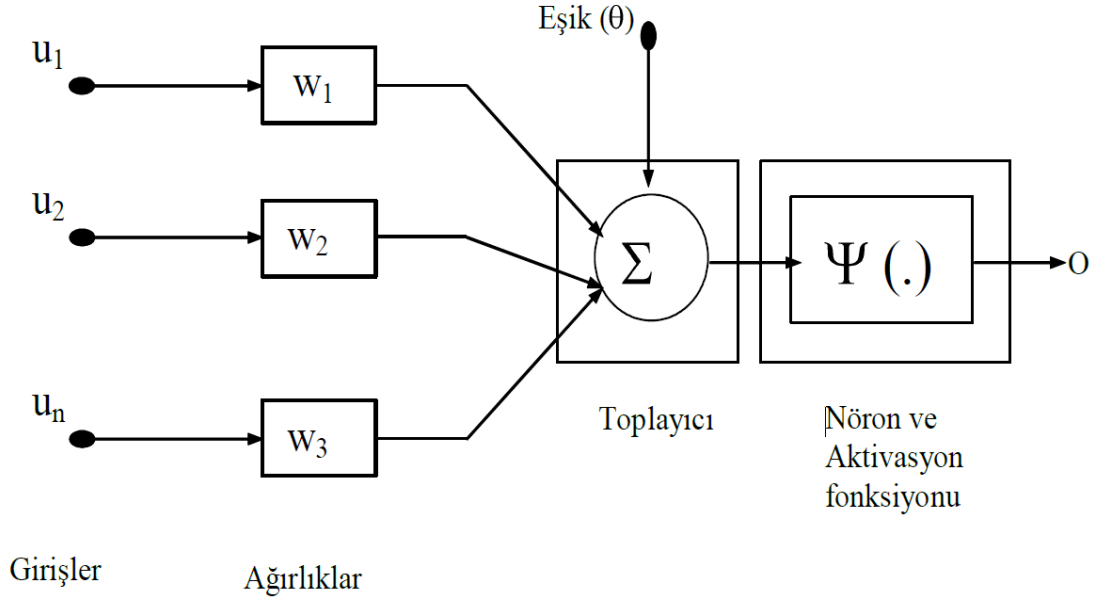
sinaptik ilişkilerin kurulması “öğrenme” sürecine karşılık gelir (Koç, M., Balas, C. E. ve Arslan, A. 2004).



**Şekil 3.1:** Biyolojik sinir hücresi ve bileşenleri (Canan, S. 2014)

Biyolojik sinir ağlarında olduğu gibi, yapay sinir ağları da, yapay sinir hücrelerinin ya da diğer adıyla nöronların bir araya gelmesinden oluşmaktadır. Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler/girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır (Öztemel, E. 2003). Şekil 3.2’de yapay sinir hücresi gösterilmiştir. Görüleceği gibi, nöron girdileri sinaptik bağlantılar üzerindeki

ağırlıklar ile çarpılarak bir toplayıcıya uygulanmakta ve elde edilen toplam, nöronun aktivasyon fonksiyonundan geçirilerek çıkışlar hesaplanmaktadır.



Şekil 3.2: Yapay sinir hücresi (Efe, Ö ve Kaynak, O. 2000)

**Girdiler:** Girdiler nöronlara gelen verilerdir. Girdiler yapay sinir hücresine bir diğer hücreden gelebileceği gibi direk olarak dış dünyadan da gelebilir. Ağın öğrenmesini istediğimiz örnekleri tarafından belirlenirler.

**Ağırlıklar:** Yapay sinir hücresine gelen bilgiler girdiler üzerinden çekirdeğe ulaşmadan önce geldikleri bağlantıların ağırlığıyla çarpılarak çekirdeğe iletilir. Bu sayede girdilerin üretilecek çıktı üzerindeki etkisi ayarlanabilmektedir. Bu ağırlıkların değerleri pozitif, negatif veya sıfır olabilir. Ağırlığı sıfır olan girdilerin çıktı üzerinde herhangi bir etkisi olmamaktadır. Ağırlıkların büyük, küçük veya eksi olması önemli veya önemsiz olduğu anlamına gelmez.

**Toplama Fonksiyonu:** Bir hücreye gelen net girdiyi hesaplayan fonksiyondur. Bu fonksiyonda bazı durumlarda gelen girdilerin değeri dikkate alınırken bazı durumlarda ise gelen girdilerin sayısı önemli olabilmektedir. Bir

problem için en uygun toplama fonksiyonu belirlenirken geliştirilmiş bir yöntem yoktur. Genellikle deneme yanılma yoluyla toplama fonksiyonu belirlenmektedir. Bazen her hücrenin toplama fonksiyonunun aynı olması da gerekmez. Bu konulara karar vermek kullanıcıya kalmıştır. Değişik fonksiyonlar kullanılabilir, ancak genellikle ağırlıklı toplamı bulan fonksiyon kullanılmaktadır. Bu durumda bir yapay sinir hücresine ağırlıklarla çarpılarak gelen girdiler toplanarak o hücrenin net girdisi (3.1) eşitliği yardımıyla hesaplanabilir.

$$NET = \sum_i^n G_i A_i \quad (3.1)$$

Formülde G girdileri, A ağırlık, n ise bir hücreye gelen toplam girdi sayısını gösterir (Öztemel, E. 2003).

**Aktivasyon Fonksiyonu:** Hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirleyen fonksiyondur. Aktivasyon fonksiyonu içinde değişik formüller kullanılmaktadır. Bazı modeller aktivasyon fonksiyonu seçilirken türevinin hesaplanabilir olmasını şart koşmaktadır. En yaygın olarak kullanılan çok katmanlı algılayıcı modelinde genel olarak aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılır (Öztemel, E. 2003). Bu fonksiyonun formülü (3.2) eşitliğinde verilmiştir.

$$F(NET) = \frac{1}{1+e^{-NET}} \quad (3.2)$$


Formülde NET proses elemanına gelen NET girdi değerini gösterir.

**Hücrenin Çıktısı:** Aktivasyon fonksiyonunun belirlediği hücrenin çıktı değeridir. Bu değer yapay sinir ağının çıktısı olarak dış dünyaya verilebileceği gibi tekrar ağa girdi olarakta gönderilebilir. Her hücrenin birden fazla girdisi olmasına rağmen bir tek çıktısı olmaktadır. Bu çıktı birden fazla sayıda hücreye bağlanabilir.

### 3.2.2 Yapay Sinir Ağları ve Çalışma İlkesi

Yapay sinir ağları yapay sinir hücrelerinin (nöronların) birbirine bağlanmasıyla oluşan yapılardır. Bu yapıda sinir hücreleri birbirine paralel olan katmanlar içerisinde bulunurlar. Şekil 3.3'de görüldüğü gibi bir yapay sinir ağında

birbirleriyle bağlantılı sinir hücrelerinin yer aldığı girdi katmanı (input layer), çıktı katmanı (output layer) ve gizli katman (hidden layer) olmak üzere üç katman bulunmaktadır.



Şekil 3.3: Yapay sinir ağı modeli

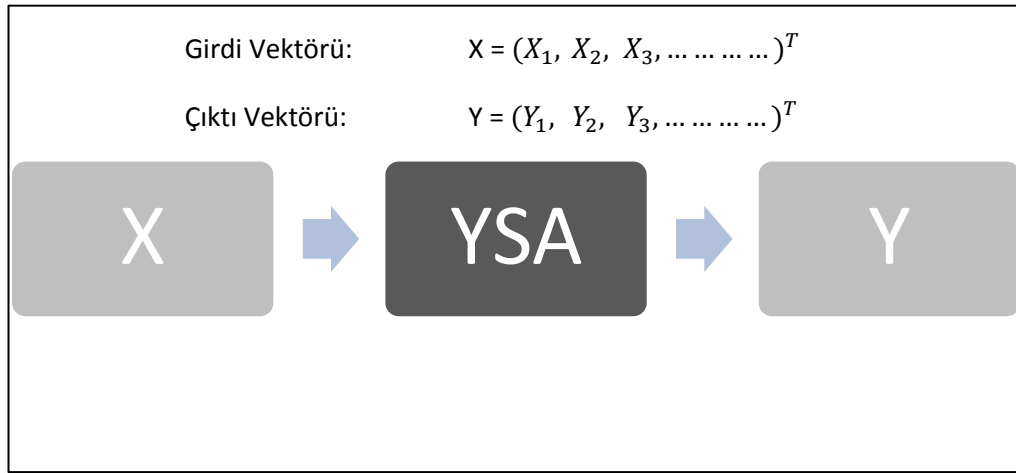
**Girdi Katmanı**, yapay sinir ağına dış dünyadan girdilerin geldiği ve bu girdilerin ara katmanlara transfer edildiği katmandır. Genelde girdiler herhangi bir işleme uğramadan alt katmanlara iletilmektedir.

**Ara (Gizli) Katmanlar**, giriş katmanından çıkan bilgiler bu katmana gelir. Bu katmanda bilgiler işlenerek çıktı katmanına gönderilir. Ara katman sayısı birden fazla olabilir.

**Çıktı Katmanı**, ara katmanlardan gelen bilgileri işleyerek, girdi seti için, ağın çıktılarını üreten katmandır. Bu katmanda üretilen çıktılar dış dünyaya gönderilir.

Yapay sinir ağlarının genel çalışma prensibi, bir girdi setini alarak bir takım işlemlerden sonra onları çıktı setine çevirmektir. Doğru çıktı setine ulaşılabilmesi

için öncelikle ağın eğitilmesi ve ağı gösterilecek girdilerin (örnekler) vektör durumuna getirilmesi gerekmektedir. Bu vektör ağı gösterilerek çıktı vektörünün üretimi sağlanır. Doğru çıktıya ulaşılabilmesi için girdi vektörü sayısal değere dönüştürülmelidir. Yapay sinir ağıının genel çalışma prensibi Şekil 3.4’de verilmiştir. (Öztemel, E. 2003).



**Şekil 3.4:** YSA girdi çıktı ilişkisi

Yapay sinir ağları girdi vektörünü çıktı vektörüne nasıl dönüştürdüğü konusunda bilgi vermemektedir. Bu duruma kara kutu yakıştırması yapılmaktadır. Bu olay yapay sinir ağına olan güveni azaltmakla beraber yapılan başarılı çalışmalar yapay sinir ağlarına olan ilgiyi arttırmaktadır.

Yapay sinir hücrelerinin bağlantılarının ağırlıklarının belirlenmesi işlemine ağı eğitilmesi denir. İlk anda ağırlık değerleri rastgele atanırlar ve örnekler ağı gösterildikçe ağırlıkların değerleri değişir. Ağırlık değerleri doğru sonuçlara ulaşana kadar bu süreç devam eder. Böylece ağı örneklerin temsil ettiği olay hakkında genellemeler yapma yeteneğine kavuşmuş olur. Ağırlık değerleri belirli kurallar doğrultusunda değişir. Bu kurallara öğrenme kuralları denmektedir. Öğrenme kurallarında ağı durumuna göre farklılıklar olabilmektedir. Öğrenme sürecinde iki aşama bulunmaktadır. İlk aşamada ağı gösterilen örnek için ağı üreteceği çıktı

belirlenir. Bu çıktı değerinin doğruluk derecesine göre ikinci aşamada ağın bağlantılarının sahip olduğu ağırlıklar değiştirilir. Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini ölçmek için yapılan denemelere ağın test edilmesi denir. Ağın testi için öğrenme sırasında görmediği örnekler kullanılır. Ağ eğitim sırasında belirlenen bağlantı ağırlıklarını kullanarak görmediği bu örnekler için çıktılar üretir. Bu testler sonucu ulaşılan çıktılar doğruluk değerleri ağın öğrenmesi hakkında bilgiler verir. Sonuçlar ne kadar iyiye, eğitim performansıda o kadar iyidir. Eğitimde kullanılan örnek setine “eğitim seti”, test için kullanılan sete ise “test seti” adı verilmektedir. (Öztemel, E. 2003).

### 3.3 Yapay Sinir Ağı Modelleri

Yapay sinir ağlarının sahip oldukları toplama ve aktivasyon fonksiyonları, öğrenme stratejisi ve kullanılan öğrenme kuralı ile ağın modelini belirlemektedir. Günümüzde çok sayıda model geliştirilmiş olup en yaygın olarak kullanılanlar şunlardır (Öztemel, E. 2003).

- Tek katmanlı algılayıcılar
- Çok katmanlı algılayıcılar (hatayı geriye yayma modelleri)
- Vektör kuantizasyon modelleri (LVQ)
- Kendi kendini organize eden model (SOM)
- Adaptif rezonans teorisi modelleri (ART)
- Hopfield ağları
- Counterpropagation ağı
- Neocognitron ağı
- Boltzman makinesi
- Elman ağı

*Tek katmanlı algılayıcılar*, sadece girdi ve çıktı katmalarından oluşup her ağın bir veya daha çok girdisi ve çıktısı bulunur. Çıktı üniteleri bütün girdi ünitelerine bağlanır ve bu bağlantıların bir ağırlığı mevcuttur. Ayrıca ağın çıktısının sıfır olmasını önleyen eşik değeri de bulunur. Bu ağlarda çıktı fonksiyonu doğrusal fonksiyondur ve iki sınıfı birbirinde ayıran doğru bulunmaya çalışılır (Öztemel, E. 2003).

*LVQ ağı* Kohonen tarafından 1984’te geliştirilmiştir. N boyutlu bir vektörü bir vektörler setine uyarlamak temel felsefesidir. Bu ağlar genelde sınıflandırma

problemlerinin çözümünde kullanılırlar. Çıktılardan birtanesi 1 diğerleri 0 değerini alır. Çıktının 1 olması girdinin ait olduğu sınıfı gösterir. LVQ ağı eğitilirken her iterasyonda çıktının değeri yerine sadece doğru olup olmadığı belirlenir. Diğer ağlardaki gibi ağın ağırlıkları öğrenme katsayısına göre değiştirilir (Öztemel, E. 2003).

*SOM ağları*da Kohonen tarafından geliştirilmiştir. Genel olarak sınıflandırma amaçlı kullanılmaktadır. Girdi vektörlerini sınıflandırma ve dağılımını öğrenebilme yetenekleri yüksektir. Bu ağların en temel özelliği ise olayları öğrenmek için ağın üretmesi gereken çıktılardan ağa verilme zorunluluğu olmamasıdır. Özellikle beklenen çıktılardan belirlenemediği problemler için kullanılırlar (Öztemel, E. 2003).

*ART ağları* 1976 yılında Grosberg'in biyolojik beynin fonksiyonlarına yönelik yaptığı çalışmalar sonucunda ortaya çıkmıştır. ART ağında öğretmensiz öğrenme stratejisi kullanılmaktadır. ART ağlarının en temel özelliği sınıflandırma problemleri için geliştirilmiş olmalarıdır. ART ağlarının LVQ ağlarından farkı yapılacak sınıflandırma ile ilgili olarak bilgi verilmemesidir (Öztemel, E. 2003).

*Hopfield ağı* Hopfield tarafından geliştirilmiş tek katmanlı ve geri dönüşümlü bir ağıdır. Proses elemanlarının tamamı hem girdi hem de çıktı elemanlarıdır. Bu ağın en önemli uygulamalarından biri geleneksel optimizasyon algoritmaları ile çözümü çok zor olan veya mümkün olmayan gezgin satıcı problemlerini çözmesidir (Öztemel, E. 2003).

*Counterpropagation ağları* Robert Hect-Nielsen tarafından geliştirilmiştir. Yapı olarak ÇKA ağına benzemektedir. Daha hızlı öğrenebilme yeteneğine sahiptirler. Counterpropagation ağları Kohonen ve Grosberg ağlarının olumlu yanlarını alarak bu ağların birleştirilmeleri ile oluşturulmuştur. Ağın eğitiminden sonra eksik veya yanlış değerler içeren girdiler için doğru çıktı vektörlerini oluşturabilmektedir. Bu sayede özellikle şekil tanıma problemlerinde etkin olarak kullanılmaktadır. *Neocognitron ağlarının* temel yapısı benzer olmakla birlikte bu ağlar daha etkindir. Resim rotasyonu, aynı şeklin farklı farklı durumlarının gösterimi ve bozulmalar gibi durumlarda daha doğru tanımlama yaparak insan görme sistemini daha doğru modellemektedir (Öztemel, E. 2003).

1983 yılında Hinton ve Sejnowski tarafından geliştirilen *Boltzman makinesi ağı* olasılıksal katılımlıdır ve geri besleme bağlantıları Hopfield ağına benzemektedir. Boltzman makinesi model seviyelerini araştırıp durum uzayında kavramları benzeterek birleştirir. Hopfield ağına ilave olarak özgün modelleme tekniğinde ki benzer işlev ve işlemleri kullanmaktadırlar (Elmas, Ç. 2003).

*Elman ağları* geri dönüşümlü ağlar arasındaki en basit yapıya sahip olan ve kullanılması en kolay ağıdır. Çok katmanlı algılayıcı ağının öğrenme kuralına göre öğrenir. Girdi elemanları, ara katman elmanları, çıktı elemanları ve içerik elemanları olmak üzere 4 çeşit proses elemanına sahiptir.

Tezdeki problemin çözümünde bu modeller arasından daha uygun olduğunu düşündüğümüz çok katmanlı algılayıcılar seçilerek çalışma yapılmış ve başarılı sonuçlar elde edilmiştir. Çok katmanlı algılayıcılar izleyen bölümde tanıtılmıştır.

### **3.4 Çok Katmanlı Algılayıcılar**

Doğrusal olmayan olayların çözümü için çok katmanlı algılayıcılar (ÇKA) geliştirilmiştir. Bu bölümde çalışmada da kullanılan bu ağ hakkında bilgiler verilecektir.

Çok katmanlı ağın yapısı Şekil 3.3'te verilmiştir. ÇKA'nın temel amacı ağın beklenen çıktısı ile üretmiş olduğu çıktı arasındaki farkı en aza indirmektir. ÇKA ağında girdi katmanından ağa sunulan bilgiler ara katmanlardan geçerek çıktı katmanına ulaşır ve ağa sunulan girdilere karşılık ağın cevabı dış dünyaya verilir. ÇKA ağında öğretmenli öğrenme stratejisi kullanılmaktadır. Bu stratejide ağa hem örnekler hem de örneklerden elde edilmesi beklenen çıktı değerleri verilir. Ağ kendisine gösterilen örneklerden genellemeler yaparak problem uzayını temsil eden bir çözüm uzayı üreterek sonradan ağa gösterilen benzer örnekler için çözümler üretebilmektedir. (Öztemel, E. 2003).

ÇKA ağının öğrenme kuralı en küçük kareler yöntemine dayalı delta öğrenme kuralının genelleştirilmiş halidir. Ağın öğrenebilmesi için örneklerden oluşan bir eğitim setine ihtiyaç vardır. Genelleştirilmiş delta kuralı *ileri doğru hesaplama* (ağın



çıktısını hesaplama kısmı) ve *geriye doğru hesaplama* (ağırlıkları değiştirme kısmı) olmak üzere iki kısımdan oluşmaktadır.

*İleri doğru hesaplama* da bilgi işleme, eğitim setindeki bir örneğin girdi katmanından (G1, G2,..) ağa gösterilmesi ile başlamaktadır. Gelen girdiler hiçbir değişiklik olmadan ara katmana gönderilir. Girdi katmanındaki  $k$ . proses elemanının çıktısı  $\zeta_k^i$ , (3.3) eşitliğinde verilmiştir.

$$\zeta_k^i = G_k \quad (3.3)$$

Ara katmandaki proses elemanlarına girdi katmanından bağlantı ağırlıklarının (A1, A2,..) etkisi ile gelen net girdi ( $NET_j^a$ )' nin formülü (3.4) eşitliği yardımıyla hesaplanabilir.

$$NET_j^a = \sum_{k=1}^n A_{kj} \zeta_k^i \quad (3.4)$$

Formulde  $A_{kj}$   $k$ . girdi katmanı elemanını  $j$ . ara katman elemanına bağlayan bağlantının ağırlık değerini gösterir.  $j$ . ara katman elemanının çıktısı net girdinin aktivasyon fonksiyonundan geçirilmesi ile hesaplanır. Aktivasyon fonksiyonu olarak genellikle sigmoid fonksiyonundan yararlanılmaktadır. Bu durumda çıktı (3.5) şeklinde olacaktır.

$$\zeta_j^a = \frac{1}{1 + e^{-(NET_j^a + \beta_j^a)}} \quad (3.5)$$

$\beta_j$ , ara katmanda bulunan  $j$ . elemana bağlanan eşik değer elemanının ağırlığını göstermektedir. Eşik değeri ünitesinin çıktısı sabit olup 1' dir. Ağırlık değeri ise eğitim esnasında ağ tarafından belirlenmektedir. Ara katmanın tüm proses elemanları ve çıktı katmanının proses elemanlarının çıktıları aynı şekilde kendilerine gelen NET girdinin hesaplanması ve sigmoid fonksiyonundan geçirilmesi ile belirlenirler. Çıktılar ( $\zeta_1, \zeta_2, \dots$ ) bulunduğu anda ağırlık ileri hesaplama işlemi tamamlanır. (Öztemel, E. 2003).

*Geriye doğru hesaplamada* ağa verilen girdi için elde edilen çıktı ağırlık beklenen çıktıları (B1, B2, ...) ile karşılaştırılır. Aradaki fark hatadır ve bu hatanın düşürülmesi hedeflenir. Bu nedenle geriye hesaplamada bu hata ağırlık değerlerine dağıtılarak bir sonraki iterasyonda hatanın azaltılması sağlanır. Çıktı

katmanındaki  $m$ . proses elemanı için oluşan hata ( $E_m$ ), (3.6) eşitliği yardımıyla hesaplanabilir.

$$E_m = C_m - B_m \quad (3.6)$$

Toplam hatayı (TH) bulmak için tüm hatalar toplanmaktadır. Bazı hata değerleri negative değer olabileceğinden toplamın sıfır olmasının önüne geçmek amacıyla ağırlıkların kareleri hesaplanarak sonucun kare kökü alınır. ÇKA ağının eğitilmesindeki amaç bu hatanın en aza indirgenmesidir. TH (3.7) eşitliği yardımıyla hesaplanır.

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (3.7)$$

Toplam hatanın en aza indirgenmesi için bu hataya neden olan proses elemanlarına dağıtılması, başka deyişle ağırlıkların değişmesi gerekir. Ağın ağırlıklarının değişiminde, ara katman ile çıktı katmanı ve ara katmanlar ile girdi katmanı arasındaki ağırlıkların değiştirilmesi olmak üzere iki durum mevcuttur.

*Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesinde*, ara katmandaki  $j$ . proses elemanını çıktı katmanındaki  $m$ . proses elemanına bağlayan bağlantının ağırlığındaki değişim miktarına  $\Delta A^a$  denirse; herhangi bir  $t$  zamanında ( $t$ . iterasyonda) ağırlığın değişim miktarı (3.8) eşitliği yardımıyla hesaplanır.

$$\Delta A_{jm}^a(t) = \lambda \delta_m C_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (3.8)$$

Formülde  $\lambda$  öğrenme katsayısını,  $\alpha$  momentum katsayısını göstermektedir. Öğrenme katsayısı ağırlıkların değişim miktarını, momentum katsayısı ise ÇKA ağının öğrenmesi sırasında yerel bir optimum noktaya takılmaması için ağırlık değişim değerinin belirli bir oranda bir sonraki değişime eklenmesini sağlar. Eşitlikteki  $\delta_m$   $m$ . çıktı ünitesinin hatasını gösterir ve (3.9) eşitliği yardımıyla hesaplanır.

$$\delta_m = f'(NET) \cdot E_m \quad (3.9)$$

Hesapta  $f'(NET)$  aktivasyon fonksiyonun türevidir. Sigmoid fonksiyonu kullanıldığında formül (3.10) şeklinde olacaktır.

$$\delta_m = \zeta_m(1 - \zeta_m). E_m \quad (3.10)$$

Değişim miktarının hesabından sonra ağırlıkların t. iterasyondaki yeni değeri (3.11) eşitliği yardımıyla hesaplanır.

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (3.11)$$

Aynı şekilde eşik değer ünitesinin de ağırlıklarını değiştirmek gerekmektedir. Çıktı katmanındaki proses elemanlarının eşik değer ağırlıkları  $\beta^c$  gösterilirse, bu ünitenin çıktısı sabit ve 1 olması nedeniyle değişim miktarı (3.12) eşitliği yardımıyla hesaplanır.

$$\Delta \beta_m^c(t) = \lambda \delta_m + \alpha \Delta \beta_m^c(t-1) \quad (3.12)$$

Eşik değerinin t. iterasyondaki ağırlığının yeni değeri,

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta \beta_m^c(t) \quad (3.13)$$

(3.13) şeklinde olacaktır.

*Ara katmanlar ve girdi katmanı arasındaki ağırlıkların değiştirilmesinde* çıktı katmanındaki proses elemanlarının hepsinin hatasından pay alması gerekmektedir. Bu ağırlıklardaki değişim  $\Delta A^i$  ile gösterilirse değişim miktarı (3.14) eşitliği yardımıyla hesaplanır.

$$\Delta A_{kj}^i(t) = \lambda \delta_j^a \zeta_k^i + \alpha \Delta A_{kj}^i(t-1) \quad (3.14)$$

Hata terimi  $\delta_j^a$  ise (3.15) formülü ile hesaplanır.

$$\delta_j^a = f'(NET) \sum_m \delta_m A_{jm}^a \quad (3.15)$$

Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanıldığında (3.16) formülü ile hesaplanır.

$$\delta_j^a = \zeta_j^a(1 - \zeta_j^a) \sum_m \delta_m A_{jm}^a \quad (3.16)$$

Hata değeri hesaplandıktan sonra yukarıdaki denklem yardımıyla değişim miktarı bulunur. Ağırlıkların yeni değerleri (3.17) eşitliği yardımıyla hesaplanır.

$$A_{kj}^i(t) = \Delta A_{kj}^i(t-1) + \Delta A_{kj}^i(t) \quad (3.17)$$

Aynı şekilde eşik değer ünitesinin ağırlıkları da değiştirilir. Ara katman eşik değer ağırlıkları  $\beta^a$  gösterilirse değişim miktarı (3.18) eşitliği yardımıyla hesaplanır.

$$\Delta \beta_j^a(t) = \lambda \delta_j^a + \alpha \Delta \beta_j^a(t-1) \quad (3.18)$$

t. iterasyondaki ağırlıkların yeni değeri (3.19) şeklinde olacaktır.

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta \beta_j^a(t) \quad (3.19)$$

Böylece ağırlıklarının tümü değiştirilmiş olur. Bir iterasyonun hem ileri hem de geri hesaplamaları tamamlandıktan sonra ikinci bir örnek verilerek sonraki iterasyona başlanır ve aynı işlemler öğrenme tamamlanıncaya kadar devam eder. (Öztemel, E. 2003).

ÇKA ağlarının çalışması şu adımlarla olur:

- *Ağın çözmesi istenilen olay için daha önce gerçekleşmiş olan örnekler toplanır.* Bu adımda ağın eğitimi ve test edilmesi için gereken örneklerin toplanması gerekmektedir. Ağın eğitimi sırasında test seti ağa gösterilmez. Ağın eğitiminden sonra test setindeki örnekler yardımıyla ağın performansının ölçümü yapılır. Seçilen örneklerin problem uzayını temsil edebilecek nitelikte olması çok önemlidir.
- *Ağın topolojik yapısı belirlenir.* Bu adımda girdi, ara ve çıktı katmanlarının adetleri belirlenmektedir. Tasarımcının deneyimi ile belirlenirler. Bu konuda geliştirilmiş bir yöntem henüz bulunmamaktadır.
- *Ağın öğrenme katsayısı, toplama ve aktivasyon fonksiyonları, momentum katsayısı gibi parametlerin belirlendiği adımdır.* Öğrenme katsayısı ağırlıkların değişim miktarını belirlemektedir. Eğer büyük değerler seçilirse ağın yerel çözümler arasında dolaşması söz konusu olabilir. Küçük değerler seçilmesi ise öğrenme zamanını

arttırmaktadır. Momentum katsayısı ise bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesidir. Özellikle yerel çözümlere takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacıyla önerilmiştir. Bu değer küçük olması yerel çözümlerden kurtulmayı zorlaştırabilir. Çok büyük değerler ise tek bir çözüme ulaşmada sorunlar yaşatabilmektedir.

- *Proses elemanlarını birbirine bağlayan ağırlık değerlerinin ve eşik değer ünitesinin ağırlıklarının başlangıç ataması yapılır.* Başlangıçta genellikle rastgele değerler atanır ve ağ uygun olan değerleri öğrenme sırasında kendisi belirler.
- *Ağın öğrenmeye başlaması ve ağırlıkların değiştirilmesi için girdi ve çıktı değerlerinin yani örneklerin gösterildiği adımdır.* Yapay sinir ağları sadece rakamlar ile çalışmaktadır. Bu nedenle girdi ve çıktılar sayısal değerde olmalı veya dönüştürülmelidir.
- *Yukarıda anlatıldığı gibi öğrenme sırasında ileri hesaplamaların yapıldığı adımdır.* Sunulan girdi için ağın çıktı değerleri belirlenmektedir.
- *Gerçekleşen çıktı ile beklenen çıktının karşılaştırılarak ağın ürettiği hata değerinin hesaplandığı adımdır.* Geri hesaplama yöntemiyle çıkan hatanın azaltılması için ağırlıkların değiştirildiği adımdır.

Bu adımlar ÇKA ağının öğrenmesi tamamlanıncaya kadar devam eder. Başka bir ifadeyle ağın öğrenmesi, gerçekleşen çıktılar ile beklenen çıktılar arasındaki hatalar kabul edilebilir düzeye ininceye kadar devam eder. Ağın öğrenmesi için durdurma kriteri genellikle üretilen hata değerinin belirli bir düzeyin altına düşmesi olarak alınmaktadır. (Öztemel, E. 2003).

ÇKA ağları hayatın neredeyse her alanında örnekleri görülen bir modeldir. Genel olarak sınıflandırma, tahmin etme, tanıma, yorumlama ve teşhis etme problemlerinde başarıyla kullanılmaktadırlar.

## 4. YAPAY SİNİR AĞLARI İLE GÜÇ TRAFOLARI ÜRETİM SÜRELERİNİN TAHMİNİ

### 4.1 Mevcut Durum ve Problemin Tanımı

Çalışma Türkiye'nin ve dünyanın en büyük trafo üreticilerinden olan ve 2005 yılından bu yana planlama bölümünde çalışmakta olduğum BEST AŞ'de yapılmıştır.

1966 yılında Balıkesir'de kurulmuş olan BEST Transformator, günümüzde modernleştirilmiş dizayn, imalat ve test bölümleri ile yağlı güç ve dağıtım transformatorleri, kuru tip dağıtım transformatorleri, reaktörler, fırın trafoları ve mekanik parçalar üretmektedir. BEST Transformator, ulusal ve uluslararası ortamda artan müşteri portföyü ve referansları ile elektromekanik sektöründe tercih nedeni olmak için büyümeyi sürdürmektedir.

Firmada siparişe dayalı üretim yapılmaktadır. Bu sistemin en belirgin özelliği mamulün az miktarlarda üretilmesi, ancak buna karşılık mamul çeşidinin fazla olmasıdır. Ayrıca siparişlerin düşük olduğu dönemlerde atıl makine ve işgücü kapasitesi ortaya çıkmakta, yüksek sipariş dönemlerinde ise siparişlerin gecikmesi söz konusu olabilmektedir. Ürün çeşitliliğinin fazla olması ve üretilen ürünlerin neredeyse hepsinin birbirinden farklı olması standart zaman hesaplarını zorlaştırmaktadır. Bunun yanında trafo imalat sürelerinin uzun ve emek yoğun çalışmanın da fazla olması standart zamanın doğru olarak hesaplanması için sıkıntı oluşturmaktadır.

Çalışmaya konu olan üretim sistemi, içinde bulunduğu yoğun ve düşük kar marjları ile çalışan rekabet çevresi dikkate alındığında, müşterilerine sunabileceği en iyi fiyat teklifini sunmak zorundadır. Dolayısıyla bu sistemde olduğu gibi siparişe göre ürün üreten ve emek yoğun çalışan işletmelerde işçilik sürelerinin maliyet üzerindeki etkisini dikkate almak, üzerinde ayrıntılı bir şekilde durulması gereken konudur.

Bu çalışma yağlı güç transformatörlerinin ön maliyet ve planlama çalışmalarında kullanılan üretim sürelerinin YSA ile tahmini için yapılmıştır. Çalışma sonunda geliştirilecek alternatif tahmin yöntemiyle daha doğru süreye daha kısa sürede ulaşılabilmek hedeflenmiştir. Böylece firma için çok önemli olan ön maliyet ve planlama çalışmalarında rekabet düzeyi arttırılacak ve bu iş için harcanan mühendislik ve işçilik süresini büyük oranda azaltılacaktır.

Belirlenecek yapay sinir ağı modelinin siparişin özelliklerine göre işin süresini tahmin edebilmesi için girdilerle çıktılar arasındaki ilişkiyi öğrenmesi gerekir. Yapay sinir ağları öğrenme işlemini örnekler yardımı ile gerçekleştirirler. Eğitim aşamasında önce ağa hiç görmediği örnekler ve bu örneklerle karşılık elde edilen çıktılar gösterilir. Eğitimin tamamlanmasının ardından ağa görmediği örnekler gösterilerek çıktının ne olacağı veya arzu edilen çıktının elde edilmesi için girdilerin ne olması gerektiği sorgulattır. Bilinen hesaplama yöntemlerinden daha farklı bir hesaplama yöntemine sahiptir. Kendi öğrenme algoritmaları vardır. Bu ağlar birbirine bağlı proses elemanlarından (yapay sinir hücrelerinden) oluşur. Her bağlantının bir ağırlık değeri vardır. Yapay sinir ağının sahip olduğu bilgi bu ağırlık değerlerinde saklı olarak ağa yayılmıştır. Öğrenme ile kastedilen topolojisi belirlenen ağın nöronlar arası bağlantı ağırlıklarının ne olması gerektiğini bulmaktır. Sonuçta öğrenmesini tamamlayan bir ağ kendine gelen girdileri toplar, nöronlarındaki aktivasyon fonksiyonlarından geçirir ve kendinden sonraki nöronlara bağlantı ağırlıkları ile çarparak iletir. Elde edilen çıktı değerinin nasıl üretildiğini gösteren bir matematiksel model yoktur. Bu nedenle yapay sinir ağlarına kara kutu benzetmesi yapılır. Öğrenme süreci, ağ kabul edilebilir çıktılar üretene kadar devam ettirilecektir.

Yapay sinir ağları buldukları ortama uyum sağlayan, eksik bilgi ile çalışabilen, belirsizlikler altında karar verebilen bir yöntemdir. Bu hesaplama yönteminin iş çizelgelemesi, kalite kontrol, sınıflandırma, örüntü tanıma, veri madenciliği, optimum rota belirleme ve optimizasyon gibi hayatın hemen her alanında başarılı uygulamalarını görmek mümkündür. Bu avantajların yanında; oluşturulacak olan ağın yapısının belirlenmesinde, ağ parametrelerinin seçiminde, belirli bir standardın olmaması, problemlerin sadece nümerik bilgiler ile

gösterilebilmesi, eğitimin nasıl bitirileceğinin bilinmemesi ve ağıın davranışını açıklayamaması bu yöntemin dezavantajıdır.

#### **4.2 Trafonun Tanımı, Özellikleri ve Üretim Süreci**

Elektrik enerjisi sadece üretildiği yerde veya çevresinde kullanılmayıp çok uzaklarda bulunan yerleşim bölgelerine, fabrikalara ve iş merkezlerine de iletilerek kullanımı sağlanır. Bunun için uygun altyapı ve yatırımına ihtiyaç duyulur. Elektrik enerjisinin uzak bölgelere iletilmesi esnasında gerek duyulan elemanların başında trafolar gelmektedir. Trafolar; elektriğin iletimi, dağıtımı ve tüketimi aşamalarında görev yapar. Özellikle iletimde görevi oldukça önemlidir.

Sezer'e göre Trafo; elektromanyetik endüksiyon yoluyla elektrik enerjisini, aynı frekansta fakat farklı gerilim ve akımda, bir veya birkaç devreye dönüştüren ve hareket eden parçası olmayan statik bir makinedir. Kısaca trafolar, elektrik enerjisinin gerilim ve akım değerlerini ihtiyaca uygun olarak değiştirebilen cihazlardır (Sezer, M. 2009). Şekil 4.1'de üretimi bitmiş yağlı trafoya ait görüntü verilmiştir.





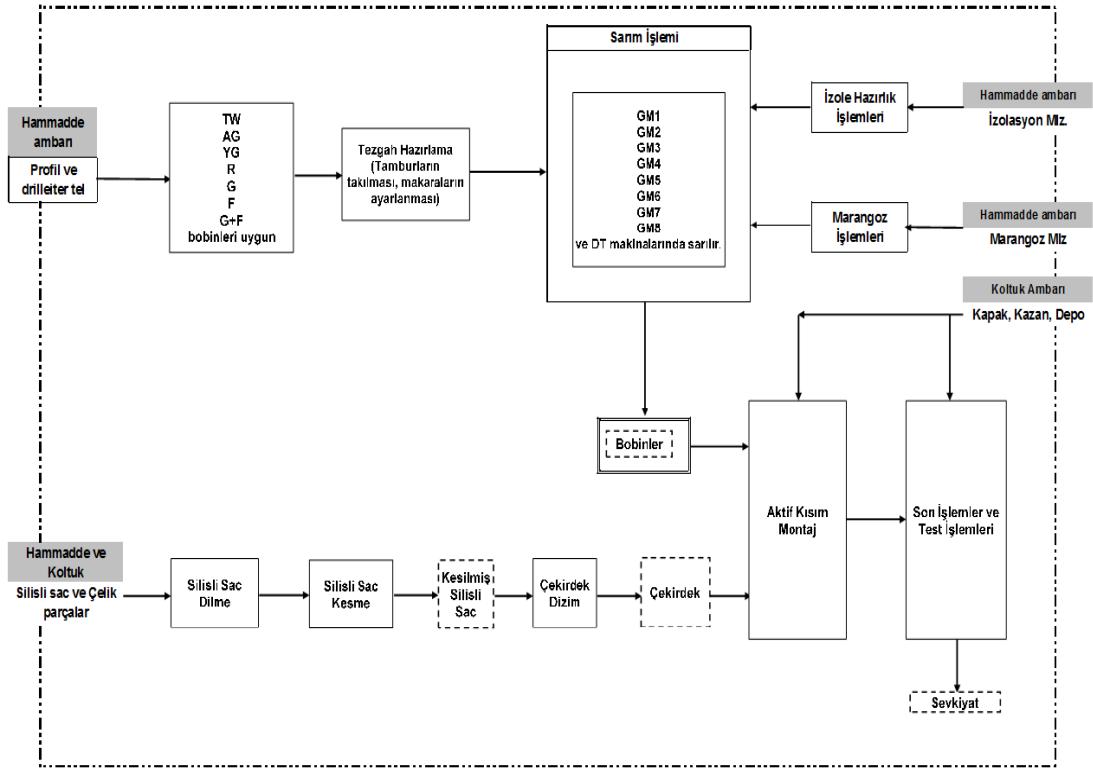
**Şekil 4.1:** Yağlı trafo

Trafo üretimi beş ana kısımdan oluşmaktadır. Bunlar sarım, dizim, mekanik üretim, montaj operasyonları ile son işlemler operasyonudur.

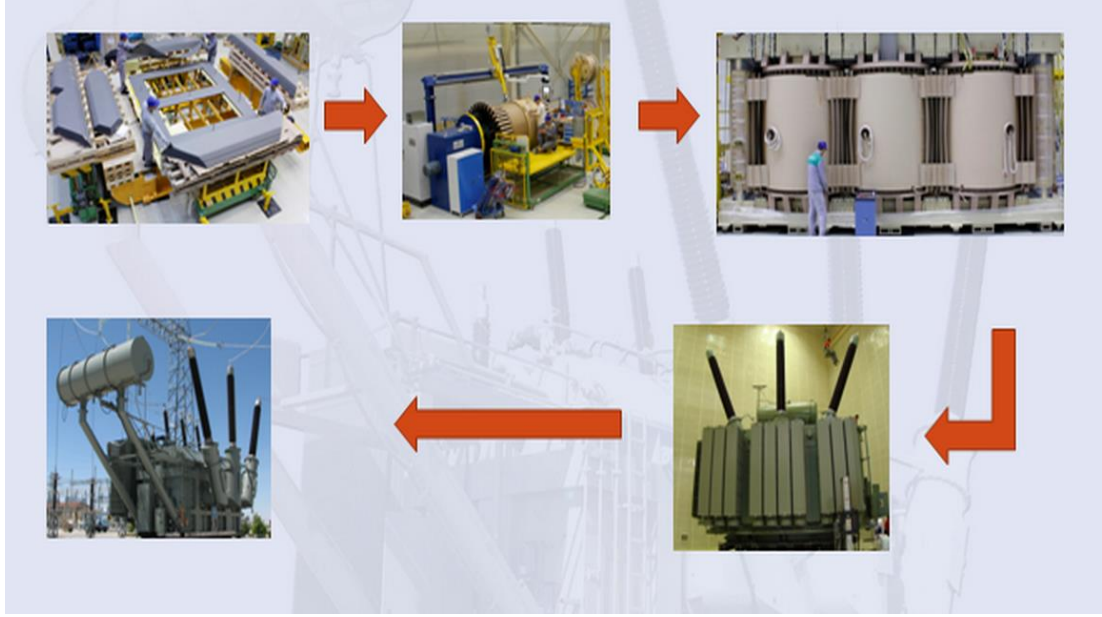
Sarım operasyonu gerekli izolasyon malzemesi hazırlama, marangozluk ve tezgah hazırlığı işlemlerinin tamamlanmasının ardından başlayarak bobinlerin alüminyum veya bakır iletken ile sarılmasıyla gerçekleştirilmektedir. Güç transformatörlerinde çoklu iletkenler ve bakır profil teller kullanılır. Gücüne, gerilim seviyesine ve müşteri isteklerine bağlı olarak farklı sarım teknikleri kullanılmaktadır.

Dizim operasyonu ise ince silisli saçların üst üste dizilmesi işlemidir. Üretiminde, iletkenliği yüksek, kayıpları düşük, kaliteli soğuk haddelenmiş silikonlu sac kullanılmaktadır. Mikroişlemci kontrollü modern makinelerde dilimlenen saçlar daha sonra çekirdek yapısına uygun olarak kesilir. Son olarak dizim tezgahlarında kesilen saçların dizim işlemi yapılır.

Sarım ve dizim operasyonlarının sonunda üretilen bobinin çekirdeğe geçirilmesi ve ara bağlantı işlemlerinin yapılması ile aktif kısım denilen bölüm tamamlanmış olur. Bu işleme aktif kısım montaj operasyonu adı verilir. Aktif kısım, kurutma işlemi için fırınlandıktan sonra mekanik üretimde tamamlanan trafo kazanına yerleştirilir. Bu operasyonun ardından son işlemler ve test işlemleri gerçekleştirilir. Bu kapsamda trafonun yağının basılması, gerekli son kontrollerinin yapılarak varsa gerekli düzeltici veya önleyici çalışmaların yapılması ve trafonun test edilmesi işlemleri yer almaktadır. Son olarak üretilen ürünler müşteriye sevk edilmek üzere mamul ambarına gönderilmektedir. Yağlı trafo akış şeması Şekil 4.2’de verilmiştir. Şekil 4.3’de ise süreç resimlerle gösterilmiştir.



Şekil 4.2: Yağlı trafo akış şeması



**Şekil 4.3:** Yağlı trafo üretim süreci (BEST A.Ş., 2014)

Soğutma durumuna göre trafolar kuru tip ve yağlı tip olmak üzere ikiye ayrılırlar. Yağlı tip trafolarının, kuru tip trafolardan farkı soğutma işleminin yağ ile yapılmasıdır. Kuru tip trafolarda ise soğutma fan ile sağlanır. Yağlı tip transformatörlerde bobinler, bakır veya alüminyum iletkenlerin sarılması ile oluşur. Bobinler ve aktif kısım fırınlama işleminden geçerler. Kuru tip transformatörlerde bobinler sarıldıktan sonra reçineyle kaplanır.

Kuru tip trafolar, yük merkezine yakın yerlere konuşlandırılabilirler için kablolama vb maliyetleri düşük olur, yani tesis maliyetleri düşüktür. Bakım gerektirmezler ve kayıpları düşüktür bu nedenle işletme maliyetleri de düşüktür. Soğutma sıvısı (trafo yağı) içermedikleri için kaçak söz konusu değildir, yangına karşı son derece dayanıklıdır ve sağlığa zararlı gaz içermezler. Bu özellikleri nedeniyle kapalı ortamlarda ve sağlık merkezleri gibi yerlerde tercih nedeni olmaktadır. En büyük dezavantajları ise fiyatlarıdır. Aynı güce sahip yağlı trafolardan 2-3 kat daha fazla satış fiyatı bulunmaktadır.

Yağlı trafolar gücüne göre dağıtım trafoları ve güç trafoları olarak ikiye ayrılırlar. Firmada 12.500 kVA ve altı dağıtım trafosu, 12.500 kVA üzeri ise güç trafosu olarak üretilmektedir. Güç trafolarının üretim ve ciro olarak payı %80-85

civarıdır. Bu nedenle çalışmada öncelikle güç trafolarının sürelerinin tahmin edilmesi tercih edilmiştir.

### **4.3 Eğitim Seti**

#### **4.3.1 Girdi ve Çıktı Verilerinin Belirlenmesi**

Firmada Oracle ERP programı kullanılmaktadır. Satış siparişinin açılmasından trafonun sevki ve yerine montajına kadar gerçekleşen tüm işlemler kullanıcılar tarafından ERP sistemine girilmektedir. Kısaca işleştikten bahsetmek gerekirse;

Satış bölümü tarafından siparişi gelen trafoya ait bilgilerin girişi yapılır. Bu bilgiler; proje no, sipariş no, trafonun gücü, gerilimi, adedi, teslim tarihi, bağlantı grubu, regel/komütatör bilgisi, soğutma şekli, yapım standardı vb genel ve teknik tüm verileri içerir.

Tasarım bölümü tarafından her bir trafo için oluşturulan ürün ağaçlarının sisteme girişi yapılır. Ürün ağaçlarında trafoda kullanılan tel, silisli sac, kara sac, şalter gibi ana kalem malzemelerin yanında civata, somun gibi tüm genel malzemelerinde özellikleri ve kullanım miktarları yer almaktadır.

Üretim bölümü, planlama tarafından açılan her bir yarımamul/mamul iş emrine işçilik girişlerini ve ürün ağaçlarından gelen malzeme çıkışlarını yapar. Aynı şekilde satınalma, sevkiyat, kalite vb tüm süreç sistemde kayıt altına alınmaktadır.

Özetle girdi verileri, Oracle ERP raporlama programı olan discoverer kullanılarak kullanıcıların girmiş olduğu verilerin raporlanması ile elde edilmektedir. Bu veriler trafonun sipariş ve teknik bilgileri, kullanılan malzeme miktarı ve iş emirlerine çıkılan işçilik süreleridir.

Yöntemin uygulanması “Matlab” bilgisayar programının yapay sinir ağıları modülü (Neural Network Toolbox) ile gerçekleştirilmiştir. Veriler, bilgisayara

girilmeden önce normalize edilmiş, yani “-1 ile 1” arasında bir değer alabilmesi için tüm veriler serideki en büyük sayıya bölünerek elde edilen rakamlar kullanılmıştır.

Çok sayıda denemeler yapılarak eğitim gerçekleştirilmiş daha sonra test için ayrılan veriler ile kurulan tüm modeller test edilmiştir. Test işlemi sonucunda bulunan öngörü değerleri, gerçek değerlerle karşılaştırılmıştır.

Modelde “ileri sürümlü (feed forward)” ağ yapısı kullanılmış, parametrelerin güncellenmesi için “hata geriye yayma (back propagation)” algoritmasından yararlanılmıştır. Çalışmada süreyi en çok etkileyen veriler toplanarak eğitimde kullanılmıştır.

Girdiler aşağıdaki parametrelerden oluşmaktadır;

*Girdiler;*

Güç: Trafonun gücü

Gerilim: Trafonun gerilimi

Boşta/Yükte: Kademe değiştiricinin yükte/boşta olması durumu

Silisli sac ağırlığı: Çekirdek üretiminde kullanılan silisli sac ağırlığı

Bakır ağırlığı: Bobin üretiminde kullanılan bakır ağırlığı

Kara sac ağırlığı: Kazan üretiminde kullanılan kara sac ağırlığı

Yağ: Son montajda kullanılan yağ ağırlığı

*Çıktı;*

Süre: Bir trafo için toplam üretim süresi.

Girdilerin tümünün minimum ve maksimum değer aralıkları Tablo 4.1’ de verilmiştir.

**Tablo 4.1:** Girdilerin minimum ve maksimum değer aralıkları

Teknik Özellikler	Seviye		
	Birim	Min	Max
Gücü	kVA	50	800.000
Gerilimi	kV	6,3	750
NLTC/OLTC	-	NLTC	OLTC
Silisli sac ağırlığı	Kg	4.000	200.000
Bakır ağırlığı	Kg	1.250	85.000
Kara sac ağırlığı	Kg	1.250	85.000
Yağ ağırlığı	Kg	2.000	140.000

### 4.3.2 Girdi ve Çıktıların Ölçeklendirilmesi

Sigmoid fonksiyonu sadece 0-1 değerleri arasında sonuç verdiği için ve uygulamada farklı transfer fonksiyonları kullanıldığından tüm girdi ve çıktılar normalize edilmiştir.

Çeşitli normalizasyon işlemleri olmakla beraber bu uygulamada veriler daha büyük değere bölünerek normalize edilmiştir.


Çalışmada 7 girdi 1 çıktı olmak üzere toplam 245 örnekten yararlanılmıştır. Ticari sır olmasından dolayı çalışmada kullanılan verilerden 20 adet örneklem seçilerek örnek olması açısından Tablo 4.2 'de belirli bir katsayıya bölünmüş olarak verilmiştir.

**Tablo 4.2:** Örnek veri tablosu

<b>GÜCÜ kVA</b>	<b>GERİLİMİ</b>	<b>B/Y KODU</b>	<b>SİLİSLİ SAC</b>	<b>BAKIR</b>	<b>KARA SAC</b>	<b>YAĞ</b>	<b>SÜRE</b>
0,3865	0,648	0,1	0,3858	0,321652	0,321744	0,524	0,3122906
0,1	0,22	0,1	0,0448	0,07508	0,132796	0,2032	0,1607784
0,1	0,22	0,1	0,0448	0,075244	0,131572	0,2032	0,1427294
0,23	0,38	0,1	0,1947	0,10904	0,192804	0,245	0,1315236
0,13	0,3	0,1	0,13874	0,106316	0,142404	0,1828	0,1241224
0,2	0,42	0,2	0,19991	0,078528	0,202468	0,2528	0,1648076
0,07615	0,161	0,2	0,06628	0,039656	0,0628	0,0812	0,0611054
0,07615	0,161	0,2	0,06628	0,039632	0,062528	0,0812	0,0623226
0,0742	0,161	0,2	0,06736	0,039636	0,06228	0,0804	0,0607624
0,0742	0,161	0,2	0,06736	0,039688	0,062064	0,0804	0,0592614
0,009	0,0315	0,2	0,0113	0,007804	0,011848	0,0144	0,0160044
0,009	0,0315	0,2	0,0113	0,007812	0,011836	0,0144	0,014691
0,0135	0,033	0,2	0,01532	0,016752	0,015196	0,02	0,0185196
0,0135	0,033	0,2	0,01532	0,016548	0,015196	0,02	0,017483
0,0135	0,033	0,2	0,01532	0,016784	0,015196	0,02	0,0176256
0,016	0,154	0,1	0,02125	0,01514	0,0306	0,04	0,0350266
0,035	0,154	0,1	0,033464	0,027456	0,039308	0,0636	0,0417936
0,02	0,033	0,1	0,01856	0,01778	0,028224	0,0336	0,028073
0,02	0,033	0,1	0,01856	0,017804	0,028224	0,0336	0,0255004

#### **4.4 Tasarlanan ađın yapısı**

Tasarlanan ađın yapısı Şekil 4.4’de verilmiştir. Bu yapıda; işin süresi, alınan siparişin özelliklerine göre (güç, gerilim, bakır ağırlığı vb.) tahmin edilebilecektir.



**Şekil 4.4:** Tasarlanan yapay sinir ağı modeli

Ağın eğitiminde 245 adet veri seti kullanılmıştır. Yapay sinir ağı mimarisi olarak ileri beslemeli sinir ağı, öğrenme tipi olarak denetimli öğrenme, öğrenme algoritması olarak da hatayı geriye yayma algoritması kullanılmıştır. Yapay sinir ağındaki gizli tabaka katman sayısı, gizli katmandaki nöron sayısı, öğrenme derecesi, momentum katsayısı ve iterasyon sayısı deneme yanılma yoluyla seçilmiştir. Yapay sinir ağının eğitimi tamamlandıktan sonra test işlemine geçilmiştir. Test işleminde daha önceden eğitimde kullanılmayan 10 adet veri seti kullanılmıştır. Test verileri ve YSA ile elde edilen çıktılar Tablo 4.3’de verilmiştir.



**Tablo 4.3:** Test verileri

TEST SAYISI	GÜCÜ	GERİLİMİ	B/Y KODU	SİLİSLİ SAC	BAKIR	KARA SAC	YAĞ	SÜRE	YSA SÜRE	Mutlak Hata oranı
1	0,01	0,132	0,1	0,01399	0,007628	0,028648	0,0388	0,03524	0,0334	94,78%
2	0,04	0,11	0,1	0,0304	0,043896	0,063424	0,006	0,0557	0,0533	95,69%
3	0,106	0,132	0,1	0,0882	0,060116	0,072144	0,0992	0,08254	0,0891	92,05%
4	0,08	0,08	0,1	0,07684	0,073264	0,1036	0,1288	0,1172	0,112	95,56%
5	0,04	0,22	0,1	0,06076	0,046424	0,102536	0,1604	0,09616	0,0976	98,50%
6	0,073	0,11	0,1	0,04597	0,071796	0,078572	0,112	0,0882	0,0868	98,41%
7	0,1	0,154	0,1	0,0851	0,065568	0,056332	0,096	0,0848714	0,0783	92,26%
8	0,1	0,154	0,1	0,0851	0,065476	0,056268	0,096	0,0771704	0,0783	98,54%
9	0,125	0,38	0,1	0,12896	0,084288	0,148068	0,1876	0,1186284	0,1209	98,09%
10	0,125	0,38	0,1	0,12898	0,084416	0,150936	0,1876	0,114442	0,1228	92,70%

Yapay sinir ağlarının eğitim ve test işleminde Matlab programının Neural Network toolbox'ı kullanılmıştır. Ayrıca bu çalışmada gizli katman sayısı 2, bu katmandaki nöron sayısı 4-16 arası, öğrenme derecesi 0.01-0.40 arası, momentum katsayısı 0.30-0.9 arası ve iterasyon sayısı ise 200000 alınarak sonuca ulaşılmıştır.

Uygulamada denenen yapay sinir ağları Tablo 4.4'de verilmiştir. Görüleceği üzere optimum ağın değerleri şu şekilde gerçekleşmiştir;

Girdi nöron sayısı: 7

Gizli katman(1) nöron sayısı:13

Gizli katman(2) nöron sayısı:13

Çıktı nöron sayısı: 1

Girdi fonksiyonu: logsig

Gizli katman(1) fonksiyonu: tansig

Gizli katman(1) fonksiyonu: tansig

Çıktı fonksiyonu: logsig

İterasyon :200000

Öğrenme derecesi: 0.35


Momentum Katsayısı: 0.90

Test verisi çıktı değeri: 0.858 (Gerçekleşen değeri:0.0856)

**Tablo 4.4:** Denenen yapay sinir ağları

AĞ	KATMANLAR				FONKSİYONLAR				İTERASYON	MC	LR	msemin	LROPT	MCOPT	Pt değeri(gerçekleşen veri)	Pt çıktı değeri (test verisi)	Tahmin Hatası (%)
	GİRDİ	ARA-1	ARA-2	ÇIKTI	GİRDİ	ARA-1	ARA-2	ÇIKTI									
1	7	4	4	1	logsig	logsig	logsig	logsig	100000	0.50 0.60 0.70 0.80	0.01 0.07 0.10 0.15	8,2732	0,07	0,7	0,0856	0,065	24,0654
2	7	8	8	1	logsig	logsig	logsig	logsig	200000	0.60 0.70 0.80	0.01 0.07 0.15	8,5379	0,15	0,6	0,0856	0,0754	11,9159
3	7	12	12	1	tansig	logsig	logsig	tansig	200000	0.60 0.70 0.80	0.01 0.07 0.15	9,0268	0,07	0,60	0,0856	0,0907	5,9579
4	7	12	12	1	logsig	logsig	logsig	pureline	200000	0.60 0.70 0.80	0.01 0.07 0.15	8,723	0,07	0,8	0,0856	0,0782	8,6449
5	7	12	12	1	pureline	logsig	logsig	pureline	200000	0.60 0.70 0.80	0.01 0.07 0.15	8,8112	0,01	0,70	0,0856	0,0792	7,4766
6	7	12	12	1	tansig	tansig	tansig	tansig	200000	0.40 0.50 0.60 0.70 0.80 0.90	0.01 0.05 0.10 0.15 0.20 0.25	7,0505	0,2	0,70	0,0856	0,0787	8,0607
7	7	13	13	1	tansig	tansig	tansig	tansig	200000	0.30 0.40 0.50 0.60 0.70 0.80 0.90	0.01 0.05 0.10 0.15 0.20 0.25 0.30	6,4253	0,01	0,70	0,0856	0,0827	3,3879
8	7	13	13	1	tansig	tansig	tansig	tansig	200000	0.30 0.40 0.50 0.60 0.65 0.70 0.75 0.80 0.90	0.01 0.05 0.10 0.15 0.20 0.25 0.30 0.35 0.40	6,4253	0,05	0,60	0,0856	0,0827	3,3879
9	7	13	13	1	logsig	tansig	tansig	logsig	200000	0.30 0.40 0.50 0.60 0.65 0.70 0.75 0.80 0.90	0.01 0.05 0.10 0.15 0.20 0.25 0.30 0.35 0.40	5,5131	0,35	0,90	0,0856	0,0858	0,2336
10	7	14	14	1	logsig	logsig	logsig	tansig	200000	0.60 0.70	0.01 0.05 0.1	9,2078	0,05	0,60	0,3123	0,0282	90,9702
11	7	14	14	1	logsig	logsig	logsig	logsig	100000	0.50 0.60 0.70 0.80 0.90	0.01 0.07 0.10 0.15 0.20 0.25	8,307	0,1	0,50	0,0856	0,0761	11,0981
12	7	14	14	1	tansig	tansig	tansig	tansig	100000	0.50 0.60 0.70 0.80 0.90	0.01 0.07 0.10 0.15 0.20	8,2339	0,1	0,50	0,0856	0,0765	10,6308
13	7	14	14	1	logsig	tansig	logsig	tansig	100000	0.60 0.70 0.80	0.01 0.05 0.10 0.15	8,6756	0,1	0,8	0,0856	0,0781	8,7617
14	7	14	14	1	logsig	tansig	logsig	tansig	100000	0.60 0.70 0.80	0.01 0.05 0.10 0.15	6,1725	0,15	0,7	0,0856	0,0837	2,2196
15	7	14	14	1	tansig	tansig	tansig	tansig	200000	0.30 0.40 0.50 0.60 0.70 0.80 0.90	0.01 0.05 0.10 0.15 0.20 0.25 0.30	7,7141	0,2	0,70	0,0856	0,0788	7,9439
16	7	15	15	1	logsig	logsig	logsig	tansig	200000	0.60 0.70 0.80	0.01 0.07 0.15	8,2534	0,07	0,80	0,0856	0,0732	14,4860
17	7	15	15	1	logsig	logsig	logsig	tansig	200000	0.60 0.70 0.80	0.01 0.07 0.15	8,7919	0,07	0,60	0,0856	0,0702	17,9907
18	7	16	16	1	logsig	logsig	logsig	logsig	200000	0.60 0.70 0.80	0.07 0.15	8,4914	0,15	0,60	0,0856	0,0792	7,4766
19	7	16	16	1	logsig	tansig	tansig	logsig	200000	0.60 0.70 0.80	0.07 0.15	8,4943	0,15	0,60	0,0856	0,0758	11,4486

Test işleminden sonra elde edilen yapay sinir ağları çıktıları ile gerçekleşen sürelerin değerleri arasındaki ilişki Şekil 4.5’de verilmiştir. Şekilde de görüldüğü üzere YSA ile elde edilen süreler gerçekleşen sürelere çok yakın ve başarılı bir şekilde tahmin edilmiştir.



**Şekil 4.5:** Gerçek süreler ile YSA ile tahmin edilen sürelerin karşılaştırması

Eğitim sonucunda elde edilen ağırlık katmanları arasındaki ağırlık değerleri Tablo 4.5, Tablo 4.6 ve Tablo 4.7’de verilmiştir.

**Tablo 4.5:** Girdi katmanı ile 1. ara katman arasındaki ağırlık değerleri

		Girdi katmanı						
	Nöron	1	2	3	4	5	6	7
1. ara katman	1	-1,3089	0,6709	0,4463	1,3947	2,0791	-2,3987	1,1902
	2	-2,7804	1,6465	1,4077	-,3082	1,0156	1,0020	0,9221
	3	0,4838	2,7296	0,9346	2,4150	-1,7528	0,0777	-0,6548
	4	1,0661	-2,0362	-2,3611	0,6769	-0,8833	1,9820	0,3571
	5	-0,7029	-1,0282	-2,0499	-0,9561	-1,2640	2,3670	-0,7853
	6	-1,8105	-1,5773	0,7154	0,6303	-2,3637	1,9201	0,6241
	7	-2,1091	1,7766	-0,601	2,0658	0,8973	-1,4680	1,1511
	8	-1,4284	2,708	-1,8336	-0,0398	1,3371	-1,1688	-0,5875
	9	-1,3040	-2,3321	1,574	-0,3246	1,2117	-2,2858	-0,5512
	10	0,4727	-0,2172	-0,996	0,6033	2,2933	2,8586	-1,0033
	11	-0,4549	-0,0721	2,125	-2,2888	1,4886	1,6861	1,5401
	12	-1,6120	-1,8166	-0,7271	-2,0309	0,8447	1,3666	-1,7796
	13	-0,7741	-0,8046	1,3953	-1,3253	2,1759	-2,3349	1,1145

**Tablo 4.6:** 1. ara katman ile 2. ara katman arasındaki ağırlık değerleri

		1. Ara katman												
	Nöron	1	2	3	4	5	6	7	8	9	10	11	12	13
2. ara katman	1	0,7973	-0,195	-0,318	-0,168	0,7737	0,5901	0,4078	-0,29	0,1519	-0,374	-0,712	0,4703	-0,173
	2	0,5181	-0,488	-0,01	-0,32	0,3507	-0,468	0,7946	-0,703	0,1434	-0,738	0,3532	0,3655	-0,019
	3	-0,438	-0,606	0,1668	0,5304	0,3476	-0,56	-0,592	0,4322	0,4250	0,5300	-0,072	-0,593	-0,499
	4	0,0210	-0,6808	0,1742	-0,044	0,3303	-0,715	0,6294	-0,325	-0,143	-0,822	0,1142	0,6207	-0,402
	5	-0,893	-0,608	-0,233	0,3795	0,4642	-0,073	-1,206	0,8731	0,2239	0,6078	0,4945	0,2060	-0,791
	6	0,0698	0,3004	0,1712	-0,2360	-0,1374	-0,7901	0,6164	-0,5202	-0,4982	0,2982	-1,0784	0,1176	0,4859
	7	-1,1042	0,3352	0,6543	0,5571	0,1767	-0,6694	-0,1764	0,4550	0,0708	0,0178	0,9654	-0,0915	-0,4759
	8	-0,8893	0,0727	0,1730	0,7408	0,3880	0,2364	-0,5405	0,0510	0,6618	-0,6546	0,0506	0,9091	0,7949
	9	0,8765	1,2870	0,1318	-0,4767	-1,1236	-0,5474	-0,2500	-1,0438	0,2632	-0,4682	-0,6472	-0,4289	0,4914
	10	0,5576	-0,0274	0,1013	0,1407	0,5316	-0,5076	-0,5403	0,2688	-0,9752	0,0420	0,3656	0,5564	0,3131
	11	0,0617	0,0192	0,2828	0,0673	-0,6548	-0,3342	-0,6951	0,7198	-0,5111	0,5740	-0,3494	-0,7313	0,1693
	12	-1,0840	-0,7269	-0,4306	0,3723	-0,4893	0,7003	0,3707	0,5683	-0,5978	-0,6328	-0,1687	-0,3176	0,0709
	13	0,5271	0,7197	-0,4183	0,4807	0,4964	0,0824	-0,5487	0,5623	0,3008	0,4452	-0,2681	0,1596	-0,5563

**Tablo 4.7:** 2. ara katman ile çıktı katmanı arasındaki ağırlık değerleri

		1. Ara katman												
Nöron		1	2	3	4	5	6	7	8	9	10	11	12	13
çıkı katmanı	1	-0,476	-0,0295	-0,148	-0,096	1,6343	-1,283	0,6530	1,5861	-1,198	0,0870	0,0799	1,1873	-0,597

## 5. SONUÇ VE ÖNERİLER

Firmada üretilen trafoların gerçekleşen süreleri incelendiğinde, benzer ürünlerde ortaya çıkan süre farklarının +/- %9 civarında olduğu tespit edilmiştir. Yapılan inceleme Tablo 5.1’de verilmiştir. Bu durumun nedenleri, emek yoğun iş olması, malzeme özelliği, taşıma/bekleme süreleri vb olarak değerlendirilebilir.

**Tablo 5.1:** Test verileri

GÜCÜ kVA	ÜST GERİLİMİ	ALT GERİLİMİ	B/Y KODU	S.SAC	BAKIR	K.SAC	YAĞ	TOP. SÜRE	ort süre	Min süre/ort	Max süre/ort
0,1	0,154	0,0336	0,1	0,0865	0,05734	0,08212	0,096	0,075263	0,07723	93,37%	110,88%
0,1	0,154	0,0336	0,1	0,0865	0,077504	0,08202	0,096	0,07211			
0,1	0,154	0,0336	0,1	0,0865	0,06742	0,08202	0,096	0,073281			
0,1	0,154	0,0336	0,1	0,0865	0,067296	0,08202	0,096	0,075636			
0,1	0,154	0,0336	0,1	0,0865	0,067424	0,081992	0,096	0,071128			
0,1	0,154	0,0336	0,1	0,0865	0,067376	0,082652	0,096	0,073094			
0,1	0,154	0,0336	0,1	0,0865	0,067316	0,084244	0,096	0,072538			
0,1	0,154	0,0336	0,1	0,0865	0,068008	0,082252	0,0976	0,082753			
0,1	0,154	0,0336	0,1	0,0865	0,0683	0,08336	0,096	0,08563			
0,1	0,154	0,0336	0,1	0,0865	0,057756	0,0834	0,096	0,078833			
0,1	0,154	0,0336	0,1	0,0865	0,068092	0,083268	0,096	0,083182			
0,1	0,154	0,0336	0,1	0,0865	0,068948	0,082332	0,096	0,095979			
0,1	0,154	0,0336	0,1	0,0865	0,068292	0,065044	0,0976	0,082652	0,0822	92,33%	109,61%
0,1	0,154	0,0336	0,1	0,0865	0,068032	0,06358	0,096	0,079407			
0,1	0,154	0,0336	0,1	0,0865	0,06826	0,064904	0,096	0,090102			
0,1	0,154	0,0336	0,1	0,0865	0,06828	0,064916	0,096	0,08123			
0,1	0,154	0,0336	0,1	0,0865	0,06826	0,082448	0,096	0,085145			
0,1	0,154	0,0336	0,1	0,0865	0,069	0,063684	0,096	0,07978			
0,1	0,154	0,0336	0,1	0,0865	0,068208	0,065524	0,096	0,093518			
0,1	0,154	0,0336	0,1	0,0865	0,068228	0,065524	0,096	0,085957			
0,1	0,154	0,0336	0,1	0,0865	0,068168	0,064604	0,096	0,079782			
0,1	0,154	0,0336	0,1	0,0865	0,068104	0,064636	0,096	0,075892			
0,1	0,154	0,0336	0,1	0,0865	0,069	0,064604	0,096	0,07476			

YSA ile yapılan uygulama sonucu ortaya çıkan test değerleri incelendiğinde çıkan değerlerin aralığının +/- %8 olduğu (Tablo 4.3) görülmektedir. Bu değerler Tablo 5.1’de elde edilen +/-%9 luk dilim içerisinde yer aldığından çalışma başarılı bulunarak firmada kullanılmaya başlanmıştır.

Günümüz piyasa ve rekabet koşullarında gelen taleplere hızlı ve doğru bir şekilde dönebilmek şirketler için hayati önem arz etmektedir. Teklif aşamasında ürün için doğru fiyat belirleyebilmek ve kısıtlı kaynakları en verimli şekilde

kullanabilmek için gelen yeni taleplere düşük sapma ile zaman tahmini yapmak tüm firmalar için önemlidir. Tahminlerde yapılacak hatalar çoğu firma için yüksek değerde zarara yol açabilmektedir. Bu zarar teklif aşamasında işin kaçırılmasıyla olabileceği gibi alınan işin işçilik maliyetinin tahminden fazla gerçekleşmesiyle de olabilmektedir.

Yapay sinir ağları geçmişten gelen verileri işleyerek bu veriler için geleceğe yönelik uygun çözümler üreten ve birçok sektörde kullanım alanı bulan başarılı bir yöntemdir.

Bu çalışmada ele alınan problemin çözümü için yapay sinir ağları kullanılarak şu faydaların sağlanacağı düşünülmektedir.

- Teklif bölümü tarafından istenilen siparişlere ait işçilik süreleri için daha doğru ve daha kısa sürede cevap verilmeye başlanacaktır.
- Firmanın rekabet gücüne olumlu katkıda bulunarak, harcanan mühendislik sürelerinin azaltılması sağlanacaktır.
- Daha hızlı ve doğru maliyetler nedeniyle firmanın pazar payında artış beklenmektedir.
- Uluslararası rekabette avantaj elde edilecektir.
- İşe yeni başlayan veya tecrübesi olmayan bir çalışan da etkin zaman tahmini yapabilecektir.
- Firmada uzun ve zor bir çalışma olan zaman etüdü çalışmalarının hızlı ve ucuz olması sağlanacaktır.
- Süreyi etkileyen tüm faktörler ve etkileri çalışmaya dahil edildiği için daha doğru sonuçlar elde edilmesi beklenmektedir.

Bu çalışma tecrübe gerektirmemesi, hızlı olması, ucuz olması ve yapılan tahminlerde istenilen hata oranının yakalanması nedeniyle diğer tahmin yöntemlerinden daha üstündür. Firma bu çalışma sonucunda hızlı ve ekonomik bir tahmin programına sahip olmuştur.

## 6. KAYNAKLAR

Alenezi, A., Moses, S. A. and Trafalis, T.B. (2008). Real-time prediction of order flowtimes using support vector regression. *Computers & Operations Research*, 35, 3489-3503.

Alpay, Ş. ve Yüzügüllü N. (2009). Dynamic job shop scheduling for missed due date performance. *International Journal of Production Research*, 47 (15), 4047-4062.

Arizono, I., Yamamoto, A. and Ohta, H. (1992). Scheduling for minimizing total actual flow time by neural networks. *International Journal of Production Research*, 30 (3), 503–511.

Asadzadeh, S.M., Azadeh, A. and Ziaefar, A. (2011). A neuro-fuzzy-regression algorithm for improved prediction of manufacturing lead time with machine breakdowns. *Concurrent Engineering-Research And Applications*, 19 (4), 269-281.

Baykasoğlu, A. ve Göçken, M. (2009). Gene expression programming based due date assignment in a simulated job shop. *Expert Systems with Applications*, 36, 12143-12150.

Baykasoğlu, A., Göçken, M. ve Unutmaz, Z.D. (2008). New approaches to due date assignment in job shops. *European Journal of Operational Research*, 187, 31-45.

Best A.Ş. (15.06.2014), <http://www.besttransformer.com/tr/logistics.>]

Canan, S. (11.07.2014), <http://sinancanan.blogspot.com.tr/2011/03/sinirbiliminde-yeni-arayslar-1.html>.

Chen, T. and Wang, Y.C. (2013). Procedure An Iterative for Optimizing the Performance of the Fuzzy-Neural Job Cycle Time Estimation Approach in a Wafer Fabrication Factory. *Mathematical Problems in Engineering Article*, 740478.



- Chen, W. and Muraki, M. (1997). An action strategy generation framework for on-line scheduling and control system in batch processing with neural networks. *International Journal of Production Research*, 35 (12), 3483–3506.
- Efe, Ö. ve Kaynak, O. (2000). *Yapay Sinir Ağları ve Uygulamaları*. İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Elmas, Ç. (2003). *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*. Ankara: Seçkin Yayıncılık.
- Hill, T. and Remus, W. (1994). Neural network models for intelligent support of managerial decision making. *Decision Support Systems*, 11 (5), 449–459.
- Hsu, S.Y. and Sha, D.Y. (2004). Due date assignment using artificial neural Networks(ANN) under different shop floor control strategies. *International Journal of Production Research*, 42 (9), 1727-1745.
- Koç, M., Balas, C. E. ve Arslan, A. (2004). Tas Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı. *Teknik Dergi, inşaat Mühendisleri Odası Yayını*, 15 (4), 3353.
- Lee, Y. H. and Kim, S. (1993). Neural network applications for scheduling jobs on parallel machines. *Computer and Industrial Engineering*, 25, 227–230.
- Li S., Li Y., Liu Y., et al. (2005, 2007). A GA-based NN approach for makespan estimation, International Conference on Intelligent Computing. *Applied Mathematics and Computation*, 185 (2), 1003-1014.
- Öztemel, E. (2003). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık.
- Patil, R. J. (2008). Using ensemble and metaheuristics learning principles with artificial neural networks to improve due date prediction performance. *International Journal of Production Research*, 46 (21), 6009-6027.
- Philipoom, P., Rees, R. and Wiegman L. (1994). Using neural networks to determine internally-set due-date assignments for shop scheduling. *Decision Sciences*, 25 (5/6), 825–851.

Raaymakers, W. H. M., and Weijters, A. J. M. M. (2003). Makespan estimation in batch process industries: A comparison between regression analysis and neural networks. *European Journal of Operational Research*, 145, 14–30.

Sabuncuođlu, İ. ve Grgn B. (1996). A neural network model for scheduling problems. *European Journal of Operational Research*, 93, 288–299.

Sezer, M. (2009). *Trafo Bakımı ve Yalıtım Yađı*. Balıkesir: Çađdaş Basımevi.

Statake, T., Katsumi, M. and Nakamura N. (1994). Neural network approach for minimizing the makespan of the general job–shop. *International Journal of Production Economics*, 33, 67–74.

Zhu, H. P., Zhan, H. H., Liu, F.M., et al. (2008). Combination of high-level Petri net simulation and neural network ensemble and its application in the prediction of order due date. *Proceedings of Information Technology and Environmental System Sciences (ITESS)*, 4, 413-417.

# **EKLER**

## 7. EKLER

### EK A Literatür Özeti

Yazarlar	Yayın Yılı	Yöntemin Genel Sınıflaması	Kullanılan Method	İşin Tamamlanma Zamanının Belirlenmesinde Kullanılan Performans Ölçütleri Ve/Veya Ölçülen Çıktılar	Kullanılan Yöntemin Girdi Faktörleri
Philipoom ve diğerleri	1994	Regresyon analizi ve Yapay Zeka Teknikleri	YSA, nonlinear regresyon,	DD, MAD, SDL	İş ve atölye karakteristikleri
Raaymaker ve Weijters	2003	Regresyon analizi ve Yapay Zeka Teknikleri	tam faktöriyel tasarım, ANN	DD	Özdeş makine sayısı, ortalama işlem adım sayısı, ortalama çakışma, işlem sürelerinin standart sapması, iş yükü dengesi
Hsu ve Sha	2004	Regresyon analizi, Simülasyon, Yapay Zeka Teknikleri	Dağıtım kuralları, Regresyon, Yapay sinir ağları, Simülasyon, TWK, JIQ	DD, Gecikme oranı	İş ve atölye karakteristikleri
Alenezi ve diğerleri	2008	Regresyon analizi, Simülasyon,	Support Vector Regression	DD, işin akış zamanının gerçek zamanlı	Her bir işin her bir makinadaki kuyruk uzunluğu

		Yapay Zeka Teknikleri	modeli, BPN	tahmini, MAPE, RMSE	ve işin durumu
Baykasoğlu ve diğerleri	2008	Regresyon analizi, Simülasyon,	<i>ADRES, LDP, DTWK, DPPW, ANOVA</i>	DD, FT, <i>MAPE, MPE, MT</i>	Her bir istasyondaki makine sayısı, her bir işin rotası, rotalara göre işlerin işlem süreleri, siparişlerin istasyonlar arası taşınma süreleri
Zhu ve diğerleri	2008	Regresyon analizi, Simülasyon, Yapay Zeka Teknikleri	Petri-net simülasyonu, Yapay sinir ağları,	DD	farklı üretim kaynakları ve ürün tipleri
Alpay ve Yüzügünlü	2009	Regresyon analizi, Simülasyon	CR+OSLK, ANOVA, Full factorial design, Simulation	DD, MAL, MSL	Her bir işin işlem süresilerini ve operasyon sayıları, ayrı ayrı her bir iş atölyeye vardığında ve atölyeden ayrıldığında, bu işlerin herbirinin rotalarındaki ve rotaları dışındaki makinelerdeki ve kuyruklardaki toplam iş sayısını ile en son tamamlanan üç işin tahmin edilen ortalama akış zamanları
Asadzadeh ve diğerleri	2011	Regresyon analizi, Yapay Zeka Teknikleri	YSA (öğretmenli öğrenme algoritması), bulanık regresyon ve geleneksel regresyon	DD	İş ve atölye karakteristikleri
Arizono ve diğerleri	1992	Yapay Zeka Teknikleri	Gaussian machine model,	DD, FT	İşin sırası, işin işlem süresi, iş sırasında beklerken işin hazırlık süresi, işin başlangıç zamanı,

			Hopfield ağı		gerçekleşen akış zamanı
Lee ve Kim	1993	Yapay Zeka Teknikleri	Yapay sınır ağları	DD, Çevrim zamanı	İş ve atölye karakteristikleri
Hill ve Remus	1994	Yapay Zeka Teknikleri	birleşik YSA, BPN	DD, Çevrim zamanı	İş ve atölye karakteristikleri
Statake	1994	Yapay Zeka Teknikleri	Hopfield ağı, Boltzmann machine mechanism	DD, Çevrim zamanı	İş ve atölye karakteristikleri
Sabuncuoğlu ve Gürgün	1996	Yapay Zeka Teknikleri	Hopfield ağı	DD, ML, Çevrim zamanı	İşler, iş sıraları, makineler,
Chen ve Muraki	1997	Yapay Zeka Teknikleri	BPN	DD,	İş ve atölye karakteristikleri
Li ve diğerleri	2005, 2007	Yapay Zeka Teknikleri	BPN ile GA birleşiminden oluşan hibrid yöntem.	DD, işin çevrim zamanının buna bağlı olarak da tamamlanma zamanının tahmini, MSE	Paralel kaynakların ortalama sayısı, her iş için ortalama işlem adımı sayısı, işlem adımlarındaki ortalama çakışma sayısı, iş yükü dengesi ve üretim süresindeki (çevrim zamanı - makespan) standart sapma
Patil	2008	Yapay Zeka Teknikleri	Yapay sınır ağları, GA	DD,	Belirli bir iş için gerekli operasyon sayısı, işlem süreleri toplamı, bu işin işlem göreceği rotada kuyrukta bekleyen iş sayısı, aynı rotada makinalarda beklenen kuyrukta bekleme sayısı ve işlem süresi gibi genel iş ve atölye karakteristikleriyle; işlere veya atölyeye ait bazı özel karakteristikler (örneğin i. işin belirli bazı operasyonlarının işlem süreleri)
Baykasoğlu ve Gökçen	2009	Yapay Zeka Teknikleri	Gen tanımlı programla	DD, MAPE, MPE, MT	Gelen her bir iş için gerekli toplam operasyon sayısı, iş sistemden ayrılana kadar

						sistemde var olan işlerin sayısı, bir işin rotası boyunca gerek duyduğu operasyonların ortalama işlem süresi, bir işin rotası boyunca ortalama kuyrukta bekleme süresi
Chen ve Wang	2013	Yapay Zeka Teknikleri	PCA, fuzzy logic, BPN	DD, Çevrim zamanı		İşle ilgili karakteristikler