T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

YAPAY SİNİR AĞLARI KULLANARAK PARTİ BÜYÜKLÜĞÜ BELİRLEME

Hazırlayan
Uğur ATİCİ

Danışman
Yrd. Doç. Dr. Ercan ŞENYİĞİT

Yüksek Lisans Tezi

Haziran 2011
KAYSERİ

T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

YAPAY SİNİR AĞLARI KULLANARAK PARTİ BÜYÜKLÜĞÜ BELİRLEME

(Yüksek Lisans Tezi)

Hazırlayan
Uğur ATİCİ

Danışman
Yrd. Doç. Dr. Ercan ŞENYİĞİT

Haziran 2011
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Adı-Soyadı : Uğur ATİCİ

İmza : 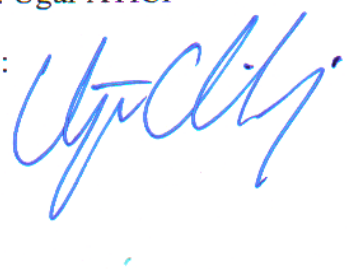

Yapay sinir ağları kullanarak parti büyüklüğü belirleme adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi'ne uygun olarak hazırlanmıştır.

Tezi Hazırlayan
Uğur ATİCİ

Danışman
Ercan ŞENYİĞİT
Yrd. Doç. Dr.

Endüstri Mühendisliği ABD Başkanı
Mithat ZEYDAN
Yrd. Doç. Dr.

Yrd.Doç.Dr.Ercan ŞENYİĞİT danışmanlığında **Uğur ATİCİ** tarafından hazırlanan **"Yapay Sinir Ağları Kullanarak Parti Büyüklüğü Belirleme"** adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü **Endüstri Mühendisliği** Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

22. 04.2011

JÜRİ:

Başkan :Doç. Dr. Mithat ZEYDAN

Üye : Yrd.Doç. Dr. Duran TOKSARI

Üye : Yrd.Doç. Dr. Ercan ŞENYİĞİT

ONAY:

Bu tezin kabulü, Enstitü Yönetim Kurulunun 02/08/2011 tarih ve 2011/26-04 sayılı kararı ile onaylanmıştır.

02/08/2011

Prof. Dr. Necmettin MARAŞLI
Enstitü Müdürü

ÖNSÖZ

"Yapay sinir ağları kullanarak parti büyüklüğü belirleme" konulu tez çalışmasının seçiminde, yürütülmesinde, sonuçlandırılmasında ve sonuçlarının değerlendirilmesinde maddi, manevi destek ve yardımlarını esirgemeyen değerli hocam sayın Yrd.Doç.Dr.Ercan ŞENYİĞİT'e, verilerin seçim kriterlerinin belirlenmesindeki katkılarından dolayı Dr. End. Yük. Müh. Aykut AYDIN'a verilerin tasnif edilmesi aşamasındaki katkılarından dolayı End. Müh. Halil YALÇIN'a, anket çalışmasına değerli katkılarından dolayı mesai arkadaşlarıma, yapay sinir ağlarının eğitimindeki değerli katılarından Hüseyin ATASOY'a, teşekkür ederim.

Tezin hazırlanması ve analizlerin yapılması konusundaki teşviklerini esirgemeyen Şube Müdürüm Sayın Mete AĞIR'a, ayrıca analiz yöntemi konusunda değerli katkılarından dolayı Bülent İLLEEZ'e teşekkür ederim.

Tez çalışmam boyunca bana verdiği manevi destek, göstermiş olduğu sabır ve anlayıştan dolayı değerli eşim Selda ATICI'ya, ayrıca her gün enerjimi tazeleyen ve hayatıma anlam katan oğlum Ertuğ ATICI'ya teşekkür ederim.

Uğur ATİCİ

Kayseri, Haziran 2011

YAPAY SİNİR AĞLARI KULLANARAK PARTİ BÜYÜKLÜĞÜ BELİRLEME

Uğur ATİCİ

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Haziran 2011
Danışman: Yrd.Doç.Dr.Ercan ŞENYİĞİT

KISA ÖZET

Son yirmi yıl içerisinde, kaynaklarının etkin bir şekilde yönetilebilmesi için stokların azaltılması, maliyetlerin düşürülmesi büyük önem kazanmıştır. Maliyetlerin azaltılması parti büyüklüğünün doğru bir şekilde belirlenmesi ile olabilir. Parti büyüklüğü belirleme problemi Wagner ve Whitin tarafından 1958 yılında geliştirilen matematiksel algoritma ile çözülmüştür. Ancak bu algoritma karmaşık olması nedeniyle birçok parti büyüklüğü belirleme metodu geliştirilmiştir. Parti büyüklüğü problemine yapay sinir ağlarının uygulandığı çalışma ise oldukça azdır.

Bu çalışmada, insan beynindeki sinir hücrelerinin çalışma prensibinden esinlenilerek geliştirilen yapay sinir ağları kullanarak parti büyüklüğü belirleme probleminde yeni bir metot geliştirilmesi amaçlanmıştır. Öncelikli olarak parti büyüklüğü belirleme problemi, yapay sinir ağları ve analitik hiyerarşi süreci hakkında teorik bilgi verilecektir. Bu çalışmada kullanılan tüm talep bilgileri 2005 ve 2009 yılları arasında olup hepsi hala canlı olan malzeme gereksinim planlama sisteminden alınmıştır. Hangi verileri yapay sinir ağlarının eğitiminde, ağın testinde ve hangilerinin ise ağ performansının değerlendirmesinde kullanılacağı sorusunu cevaplamak için analitik hiyerarşi süreci kullanılmıştır. Arzulanan çıktı verileri WinQSB programı kullanılarak Wagner ve Whitin yöntemi ile talepler çözülerek elde edilmiştir. Bu aşamadan sonra yapay sinir ağlarının sipariş planlarının elde edilmesi için farklı tipteki yapay sinir ağları oluşturulmuş ve eğitilmiştir. Bütün ağların performansları diğer ağlar ve diğer parti büyüklüğü metotları ile karşılaştırılmıştır. Sonuç olarak hangi yapay sinir ağı tipinin parti büyüklüğü belirleme problemi için en fazla kullanışlı olduğuna karar verebildik.

Anahtar Kelimeler: Parti büyüklüğü belirleme; yapay sinir ağları; analitik hiyerarşi süreci; neurosolutions.

LOT-SIZING BY USING NEURAL NETWORK

Uğur ATİCİ

Erciyes University, Graduate School of Natural and Applied Sciences
M.Sc. Thesis, June 2011
Supervisor: Assistant Professor Ercan ŞENYİĞİT

ABSTRACT

In last two decades, for effectively resource management reducing inventory and reducing cost acquired more consideration. Reducing cost can be perform by determining lot-sizing problem accurately. Lot-sizing problem has been solved by Wagner and Whitin with developed math algorithm in 1958. But, different lot-sizing methods have been developed due to complexity of this algorithm. Researches which artificial neural network is applied into lot-sizing problem are fairly seldom.

In this study, we aimed to use artificial neural network which was originated principle of human brain neural cell for improving a new method at lot-sizing problem. First of all, theoretical information about lot-sizing, analytic hierarchy and artificial neural network will be given. The all demand data which are used in this study are between 2005 and 2009 and all of them were taken from material planning system which is still alive. We use analytic hierarchy process for to answer which data will use for training, which one will use for testing neural network. Desired output data were obtained by solving demand by using WinQSB with Wagner and Whitin algorithm. After that milestone, different type of artificial neural networks were created and trained for acquire artificial neural network's order plan. All network performance were matched other network and other lot-sizing methods. Consequently, we judge that which type of neural network is most useful for lot-sizing.

Keywords: Lot-sizing; artificial neural network; analytic hierarchy process; neurosolutions.

İÇİNDEKİLER

YAPAY SİNİR AĞLARI KULLANARAK PARTİ BÜYÜKLÜĞÜ BELİRLEME

Sayfa

BİLİMSEL ETİĞE UYGUNLUK SAYFASI..... ii
YÖNERGEYE UYGUNLUK SAYFASI iii
KABUL VE ONAY SAYFASI..... iv
ÖNSÖZ..... v
ÖZET..... vi
ABSTRACT vii
İÇİNDEKİLER..... viii
TABLOLAR LİSTESİ ix
ŞEKİLLER LİSTESİ..... x

GİRİŞ..... 1

1. Bölüm

ÖNCEKİ ÇALIŞMALAR

I. Parti Büyüklüğü Belirleme 7
II. Yapay Sinir Ağları 13
III. Analitik Hiyerarşi Prosesi..... 16

2. Bölüm

YÖNTEM VE MATERYAL

I. Materyal..... 17
II. Yöntem 17

A. Parti Büyüklüğü Belirleme Problemi 17
1. Ekonomik Sipariş Miktarı 19
2. Parçalı Dönem Algoritması 20
3. En Düşük Birim Maliyet Yöntemi 21
4. En Düşük Toplam Maliyet Yöntemi 22
5. Silver-Meal Yöntemi 23
6. Wagner-Whitin Yöntemi 24
B.Yapay Sinir Ağları 25
1. Neden Yapay Sinir Ağları 26
2. Yapay Sinir Ağı Hücresi 28
3. Aktivasyon Fonksiyonları 29
a. Lineer Fonksiyon 30
b. Step Fonksiyonu 30
c. Eşik Değer Fonksiyonu 30
ç. Hiperbolik Tanjant Fonksiyonu 31
d. Sigmoid Fonksiyonu 31
e. Gauss Fonksiyonu 31
4. Yapay Sinir Ağı Modelleri 32
5. Yapay Sinir Ağlarının Eğitilmesi 33
6. Yapay Sinir Ağı Modelleri 33
a. Tek Katmanlı Ağ 33
b. Çok Katmanlı Yapay Sinir Ağı 34
c. İleri beslemeli Modüler Yapay Sinir Ağları 35
ç. Radyal Tabanlı Yapay Sinir Ağları 36
d. Kohonen Ağı 37
C. Analitik Hiyerarşi Prosesi 38
1. AHP'nin Uygulama Aşamaları 39
III. Uygulama 42
A. Verilerin Toplanması ve Düzenlenmesi 42
B. Verilerin Gruplandırılması 42
C. Eğitim ve Testlerde Kullanılacak Verilerin Seçimi 44
Ç. Optimum Çözümlerin Bulunması 48
D. Yapay Sinir Ağlarının Eğitimi 51

3. Bölüm

BULGULAR

I. Ağ Çıktısı İle Arzu Edilen Çıktıların Karşılaştırması..... 57
II. Optimum Sipariş Planına Göre Karşılaştırma..... 60
III. Optimum Maliyetten Sapma Kriterine Göre Karşılaştırma 64

4. Bölüm

TARTIŞMA-SONUÇ VE ÖNERİLER

I. Tartışma-Sonuç ve Öneriler 71
EKLER..... 104
KAYNAKLAR..... 108
ÖZGEÇMİŞ

KISALTMALAR VE SİMGELER

Sembol	Anlamı	Birimi
Cs	Sipariş Maliyeti	--
Ch	Elde bulundurma maliyeti	--
P	Birim satın alma maliyeti	--
C_h	Bir birimi 1 yıl elde bulundurma maliyeti	--
P	Birim satın alma maliyeti	--
$TRC(T)$	T dönemleri boyunca toplam ilgili maliyet	--
T	Dönemlerdeki tekrar doldurmalar gerekli süre	--
D	Talep miktarı	--
D_i	i. Dönemdeki talep miktarı	--
v	Birim maliyet	--
r	Birim stoklama maliyet oranı(%)	--
Q	Optimum Sipariş Miktarı	--
TM_{WW}	Optimal çözüm (Wagner-Whitin) siparişlerinin toplam maliyeti	--
TM_{YSA}	Yapay sinir ağı siparişlerinin toplam maliyeti	--
TM_{Sapma}	Optimum maliyetten sapma yüzdesi	--
x_i	Girdiler	--
S_c	Hazırlık Maliyeti	--
H_c	Elde bulundurma maliyeti	--
V_c	Değişken maliyetler	--
W_i	Ağılıklar	--
O_i	Çıktılar	--

TABLOLAR LİSTESİ

Tablo 1.1. Von Neumann Bilgisayarı ile biyolojik sinir sisteminin farklılıkları 67
Tablo 3.1. Karşılaştırma kriterleri için tutarlılık göstergesi. 47
Tablo 3.2. AHP sonucunda malzemelerin önem sırası. 48
Tablo 3.3. Periyotlar halinde hazırlanan veriler 48
Tablo 3.4. Wagner-Whitin yöntemi ile siparişler 50
Tablo 3.5. Sipariş planına dönüştürülmüş veriler. 51
Tablo 3.6. Eğitilen çok katmanlı yapay sinir ağı modeller. 54
Tablo 3.7. Çok katmanlı ağ oluşturulurken dikkate alınan faktörler 55
Tablo 3.8. Kendinden öğrenmeli ağ oluşturulurken dikkate alınan faktörler. 55
Tablo 3.9. Radyal tabanlı ağ oluşturulurken dikkate alınan faktörler. 56
Tablo 4.1. "r" korelasyon katsayısına göre en iyi performansı gösteren ilk 10 Yapay Sinir Ağı. 59
Tablo 4.2. WW sipariş planı. 61
Tablo 4.3. Yapay sinir ağları sipariş planı.. 62
Tablo 4.4. Sipariş planı için 0,1 atama kriteri 62
Tablo 4.5. YSA tipleri için sipariş planlarının oluşturtması 62
Tablo 4.6. Sipariş planına göre en iyi performansı gösteren ilk 10 yöntem 63
Tablo 4.7. Diğer parti büyüklüğü metotlarının sipariş planı yüzdesi ve sıralama dereceleri 63
Tablo 4.8. WW sipariş planı 65
Tablo 4.9. Yapay sinir ağları sipariş planı 65
Tablo 4.10. Sipariş planı için 0,1 atama kriteri 66
Tablo 4.11. Yapay Sinir ağları toplam maliyet hesaplanması 66
Tablo 4.12. Optimum maliyetten en az sapma gösteren ilk 10 yöntem 67
Tablo 4.13. Parti büyüklüğü yöntemlerinin Wagner Whitin toplam maliyetinden sapma yüzdeleri ve sıralama dereceleri 68

ŞEKİLLER LİSTESİ

Şekil 1.1. Parti Büyüklüğü Belirlemenin Sınıflandırılması 8
Şekil 2.1. Basit bir sinir hücresi 26
Şekil 2.2. Örüntü tanıma. 27
Şekil 2.3. Gruplama 27
Şekil 2.4. Fonksiyon yaklaştırma 28
Şekil 2.5. Tahmin. 28
Şekil 2.6. Optimizasyon. 28
Şekil 2.7. Yapay sinir ağı matematiksel modeli ve katman yapısı 29
Şekil 2.8. Lineer aktivasyon fonksiyonu 30
Şekil 2.9. Step aktivasyon fonksiyonu.. 30
Şekil 2.10. Eşik değer aktivasyon fonksiyonu. 30
Şekil 2.11. Hiperbolik tanjant aktivasyon fonksiyonu. 31
Şekil 2.12. Sigmoid aktivasyon fonksiyonu. 31
Şekil 2.13. Gauss aktivasyon fonksiyonu 32
Şekil 2.14. Ağ mimarisine göre yapay sinir ağlarının sınıflandırılması. 32
Şekil 2.15. Tek katmanlı yapay sinir ağı 33
Şekil 2.16. Çok katmanlı yapay sinir ağı topolojisi. 34
Şekil 2.17. İleri beslemeli modüler yapay sinir ağı topolojisi 35
Şekil 2.18. Radyal tabanlı ağ topolojisi. 36
Şekil 2.19. Kohonen Mimarisi 38
Şekil 2.20. Yüksek basınç elemanları grubuna ilişkin malzeme resimleri 43
Şekil 2.21. Tamirlik malzemeler grubuna ilişkin malzeme resimleri. 43
Şekil 2.22. Kit ve takım malzemeler grubuna ilişkin malzeme resimleri. 43
Şekil 2.23. Yedek parça grubuna ilişkin malzeme resimleri 44
Şekil 2.24. Hammadde ve Sarf Malzemeler grubuna ilişkin malzeme resimleri 44
Şekil 2.25. Kontrol ünitelerine ilişkin malzeme resimleri 44
Şekil 2.26. Uzman personele gönderilen anket formu girişi 45
Şekil 2.27. Uzman personele gönderilen anket formu 46
Şekil 2.28. Üretim etkinliğine göre malzemelerin karşılaştırılması 46
Şekil 2.29. Üretim etkinliği karşılaştırma matrisi 47
Şekil 2.30. Stok problemi için metot ve periyot seçimi 49
Şekil 2.31. Verilerin WinQSB programına girilmesi 49

Şekil 2.32. Problemin çözümü için algoritmanın seçilmesi 49
Şekil 2.33. WW çözümü 50
Şekil 2.34. YSA eğitiminde kullanılan verilerin ayrımı 52
Şekil 2.35. YSA eğitiminde verilerin sınıflandırılması 53
Şekil 2.36. Eğitilen ağların genel yapısı 54
Şekil 3.1. "r" değeri 0,8 den daha yüksek ağların YSA tiplerinin dağılımı 59
Şekil 3.2. "r" değeri 0,8 den daha yüksek ağların öğrenme kurallarının dağılımı 59
Şekil 3.3. "r" değeri 0,8 den daha yüksek ağların transfer fonksiyonu dağılımı 60
Şekil 3.4. Sipariş planında %80 den daha yüksek başarı gösteren yapay sinir ağların YSA tipine göre dağılımı 63
Şekil 3.5. Sipariş planında %80 den daha yüksek başarı gösteren öğrenme kuralına göre dağılımı 63
Şekil 3.6. Sipariş planında %80 den daha yüksek başarı gösteren ağların transfer fonksiyonlarına göre dağılımı 64
Şekil 3.7. Decision Analysis V1,42 programının ekran görüntüsü 66
Şekil 3.8. WW toplam maliyetinden % 0,25 den daha sapan az ağların YSA tipine göre dağılımı 67
Şekil 3.9. WW toplam maliyetinden % 0,25 den daha az sapan ağların öğrenme kuralına göre dağılımı 68
Şekil 3.10. WW toplam maliyetinden % 0,25 den daha az sapan ağların transfer fonksiyonuna göre dağılımı 69
Şekil 3.21. YSATM topolojisi 70

GİRİŞ

Günümüzde, iktisadi alanda faaliyet gösteren firmalar için yoğun rekabet baskısı altında üretim faktörlerini en uygun şekilde bir araya getirerek müşterileri beklentilerini en üst seviyede karşılamak, en önemli öncelikler arasında yer almaktadır. Devam eden üretim faaliyetleri içerisinde pazarda rekabet üstünlüğü sağlayacak ve firma kar oranın artırmasına yönelik maliyetlerde ki düşüş önem kazanmıştır. Maliyetlerde tasarruf sağlamanın en etkili yöntemi, satın almalar gerçekleştikten sonra tedarik edilen malzemelerin daha etkin nasıl kullanılır hesabının yapılmasından ziyade; maliyetler henüz gerçekleşmeden gerekli önlemlerin alınmasından geçmektedir. Maliyetleri en düşük seviyede tutulurken müşteri taleplerinin karşılanmasında pek çok faktör vardır. Ancak bunlardan en önemlisi parti büyüklüğünün belirlenmesidir.

Parti büyüklüğü belirleme problemi literatürde üretimin kapsanacağı, planlama dönemleri boyunca toplam maliyeti en düşük seviyede tutarak ortaya çıkan taleplerin karşılanmasına yönelik ürün ve malzeme miktarlarının hesaplanması olarak tanımlanmıştır. Parti büyüklüğünün belirlenmesine yönelik şimdiye kadar pek çok çalışma yapılmıştır. Bu konuda en kapsamlı çalışma 1958 yılında Wagner ve Whitin[1] tarafından yapılmış ve en uygun çözüm bulunmuştur. Wagner ve Whitin tarafından geliştirilen algoritma en uygun çözüm olmasına rağmen, anlaşılırlığının zor ve sayısal olarak karmaşık olması nedeniyle farklı bilim adamları tarafından eleştirilmiştir. Bu nedenle literatürde çok sayıda farklı parti büyüklüğü metodu geliştirilmiştir.

Yapılan çalışmaları parti büyüklüğü probleminin çözümündeki katkılarına göre iki ana başlık altında toplanabilir. Bunlardan ilki literatür taraması şeklindeki özet çalışmalardır. İkincisi ise parti büyüklüğü belirleme probleminin çözümüne yönelik yeni yöntem geliştirme ve önceki yöntemlerin iyileştirme çalışmalarıdır. İkinci

kısımdaki çalışmalar yeniden tasniflenecek olursa üç farklı ana başlık altında toplanması mümkündür. Birincisi, yeni yöntem ve metot geliştirilmesine yönelik çalışmalardır. İkincisi, daha önceden ortaya konan yöntemlerin uzantısı şeklinde olup, kullanılan metotların geliştirilmesini amaçlayan çalışmalardır. Üçüncü ise parti büyüklüğü belirleme problemini çözümüne yönelik diğer bilimsel disiplinlerin uygulandığı çalışmalardır.

Parti büyüklüğü belirleme alanında yapılan çalışmalar ilk önce talebe göre, sonra üretim düzeyine göre ve üretimde kapasite sınırının olup olmadığına göre sınıflandırılmıştır. Parti büyüklüğü belirleme problemin literatürde büyük bir dikkati üzerine toplamasının nedeni maliyetleri düşürürken talepleri tam olarak karşılamayı amaçlamasıdır. Bu amaç üzerinde, önceki çalışmalarda tam anlamıyla fikir birliğine varılmıştır. Araştırmacıların bu isteği sayesinden parti büyüklüğü belirleme probleminin çözümünde sadece klasik matematik çözümü ile yetinilmemiştir. "Problem daha etkin nasıl çözülür ve farklı şartlar altında nasıl çözülmelidir?" sorusunun cevabının aranmıştır.

Wagner- Whitin tarafından en uygun çözüm esnasında yapılan varsayımların gerçek hayatta her zaman gerçekleşmemesi, günümüz firmaların değişen taleplere ayak uydurabilmesi için üretim hatlarını esnek yapıya kavuşturmaları nedeniyle parti büyüklüğü belirleme problemi kabullerinde değişimler olmuştur. Optimum çözümde ki varsayımlar her an değişebilir mahiyete bütünmüş belirli olan şartlar ise belirsizleşmiştir. Bu tip yeni gelişmeler araştırmacıları farklı disiplinlerden faydalanmaya ve daha modern problem çözme tekniklerinin bu alanda kullanılmasına yöneltmiştir. Uygulanacak olan yeni modelde aranan özellikler ise problemin yapısındaki ve piyasa yapısındaki değişme uygun olmalıdır. Bu özellikler; çözümü kolay, karmaşık olmayan, matematiksel temellere dayanan, değişime hızlı bir şekilde adapte olabilme olarak sıralanabilir. Bu düşünceden hareketle bazı araştırmacılar parti büyüklüğü belirleme problemine yapay sinir ağlarını ve genetik algoritmayı uygulamışlardır.

Pek çok bilimsel alanda uygulama yeri bulan yapay sinir ağları; uygulaması kolay, matematiksel temellere dayanan, öğrenebilen sistemler olup parti büyüklüğü belirleme problemine uygulama çalışmaları çok az olmakla beraber, Wagner-Whitin'in

çözümünden sonra parti büyüklüğü belirleme problemindeki değişime ayak uydurabilecek potansiyele sahiptir.

Yapay sinir ağları geliştirilirken insan beyninin düşünme yapısından esinlenilerek geliştirilmiş olması, yapay sinir ağlarına pek çok olumlu avantaj kazandırmıştır. Bir nevi insan beyninin özellikleri ile bilgisayar işlemcilerinin hesaplama yeteneğinin birleştirilmesine imkân tanımıştır. Bilgisayar işlemcilerinin genel özelliği ile insan beyninin özelliklerinin birleştirilmesinin neden önemli olduğunu anlayabilmek için bu ikisinin özelliklerine bakmak yeterli olacaktır. Bu özellikler Dave Anderson ve George McNeil tarafından karşılaştırılmıştır [2]. Yapılan bu karşılaştırma 1996 yılında Anil K.J., Mao J., Mohiuddin K.M. tarafından tablolaştırılmıştır[3].

Tablo 1.1. Von Neumann Bilgisayarı ile biyolojik sinir sisteminin farklılıkları[3].

	Von Neumann Bilgisayarı	Biyolojik Sinir Sistemi
İşlemci	Karmaşık Yüksek Hız Bir veya birkaç	Basit Düşük Hız Büyük Sayıda
Hafıza	İşlemciden bağımsız Yerleşik Adreslenemeyen içerik	İşlemci ile bütünleşik Dağıtılmış Adreslenebilir İçerik
Hesaplama	Merkezi Sıralı Depolanmış programlar	Dağıtılmış Paralel Kendinden Öğrenen
Güvenirlik	Çok hassas	Güçlü
Uzmanlık	Sayısal ve sembol işleme	Anlamaya Dayalı Problemler
Çalıştırma Çevresi	İyi tanımlanmış İleri derece alışılmadık	İyi tanımlanmamış Alışılmış

Bu karşılaştırmaya göre biyolojik sinir sistemi; çok sayıdaki işlemci ile daha düşük hızda ve basit işlemleri yapabilen, kendinden öğrenen, gürültüye karşı güçlü olan sistemler olarak tanımlanmıştır. Bilgisayar sistemleri ise bir veya birkaç işlemciden oluşan, depolanmış programlar vasıtası ile çalışan, gürültüye karşı çok hassas sistemler olarak tanımlanmıştır. Yapay sinir ağları insan beynin üstün özellikleri ile bilgisayar işlemcilerinin temel özelliklerinin tek bir ortamda birleştirmeye çalışan sistemlerdir.

Yapay sinir ağlarının genel özellikleri ise insanoğlunun beyni gibi anlamaya çalışan, insansı özellikleri kopyalayan sistemler olarak tanımlayıp; mühendislik, bilim, dil kullanımı alanlarında uygulama imkânı bulan sistemler olarak tanımlanmaktadır [4]. Yapay sinir ağlarının genel olarak bu özellikleri değerlendirmeye katıldığında ise, değişime ayak uydurabilmesi, matematiksel bir temele dayanması, karmaşık problemleri kolayca çözebilme potansiyeli ve öğrenebilme yeteneği ile parti büyüklüğü probleminin yapısındaki değişime ayak uydurabilecek alternatif hesaplama araçlarından biri olarak karşımıza çıkmaktadır. Bunun yanı sıra parti büyüklüğü belirleme, üretim planlamada ki uygulamalar ile tümleşik optimizasyon problemlerinin bir türüdür. Bu problemde üretim sabit sayıda dönem ve öğelerin üretim planındaki makinelerde gerçekleşir. Bir makine üretime başlamak için doğru bir şekilde hazırlanması gerekmektedir. Hazırlık, sabit maliyetlerdeki ödeme veya makinelerin çalışma zamanlarının düşmesi anlamına gelmektedir. Parti büyüklüğü belirleme, firmalara maliyet avantajı kazandıracak önemli bir üretim planlama elemanıdır. Parti büyüklüğü belirleme probleminde en önemli kriterlerden bir tanesi toplam maliyetin düşürülmesidir. Bu sebepten dolayıdır ki parti büyüklüğü belirleme yöntemlerinin karşılaştırılmasında genellikle toplam maliyet kriteri kullanılmıştır.

Tez çalışmasında daha önceki çalışmalarda kullanılan yöntemler incelenmiştir. Bu çalışmalar yapılışı açısından bazı noktalarda diğer çalışmalar ile paralellik arz ederken bazı noktalarda ise ayrışmaktadır. Önceki çalışmalara ilişkin detaylı bilgi literatür tarama kısmında verilecektir. Kısaca bu tez çalışmasının özellikleri özetlenecek olursa;

- Uygulama ağırlıklı bir çalışmadır,
- Tek bir yapay sinir ağı topolojisi kullanılmamıştır. Çeşitli ağ tipi, öğrenme kuralı, transfer fonksiyonu gibi yapay sinir ağının öğrenmesini etkileyen çeşitli varyasyonlarda ağlar ile çalışılmıştır.
- Önceki çalışmalara uygun olarak test ve eğitim verileri ortak veri havuzundan rastgele seçilmiştir.
- Veri üretimi için kullanılacak veriler eğitim ve test verilerinden tamamen farklı tutulmuştur.
- Performans değerlendirmesinde toplam maliyet bir kriter olarak kullanılmıştır.

- Çalışmaların tamamlamasında isabeti artırmak ve hesap hatalarından kaçınmak için hesaplama aracı Visual Basic Makro kodlarından faydalanılmıştır,
- Yapılan çalışmanın doğası gereği sadece tek bir paket programdan ziyade çalışmalarda pek çok paket program kullanılmıştır,
- Toplam maliyetlerin Wagner-Whitin çözümü en iyi çözüm olarak kabul edilmiştir,
- Yapay sinir ağlarının performansı kendi aralarında ve diğer parti büyüklüğü metotları ile karşılaştırılmıştır.
- Pek çok bilimsel alanda uygulama imkanı bulmasına rağmen parti büyüklüğü belirleme probleminde oldukça az uygulanan yapay sinir ağlarının çok detaylı bir şekilde ele alınmıştır.

Sonuç olarak; maliyetleri en düşük seviyede tutulurken müşteri taleplerinin karşılanmasında en önemli faktörlerden bir tanesi parti büyüklüğünün belirlenmesidir. Parti büyüklüğü belirleme problemi, planlama dönemleri boyunca toplam maliyeti en düşük seviyede tutarak ortaya çıkan taleplerin karşılanmasına yönelik ürün ve malzeme miktarlarının araştırır. Wagner- Whitin tarafından en uygun çözüm 1958 yılında bulunmasına rağmen, yöntem karmaşık olması nedeniyle pek çok araştırmacı tarafından eleştirilmiş olup aynı zamanda çözüm esnasında yapılan varsayımlarda her şeyin belirli olduğu kabul edilmiş. Piyasa koşulları değişmiş, üretim planlama açısından pek çok karar kriteri belirsizleşmiştir. Planlama işlemlerinin basit, anlaşılabilir ve esnek olma zorunluluğu gelmiş buna karşın Wagner-Whitin'den sonra toplam maliyet açısından daha iyi sonuç veren diğer bir yöntem geliştirilememiştir. Bu durum insan gibi sezgisel tarafı güçlü olan, hesaplamaları matematiksel temellere dayanan, esnek sistemlerin parti büyüklüğü belirleme problemine uygulanması bir gereklilik halini almıştır. Pek çok bilimsel alanda başarılı bir şekilde uygulanan, hataya ve gürültüye karşı dirençli olan ve öğrenme kabiliyeti olan yapay sinir ağlarının parti büyüklüğü belirleme problemine de başarı ile uygulanabileceği Lotffi K.Gaafar [5]ve Laarhover PJ'ın[6] tarafından bildirilmiştir. Ancak toplam maliyet açısından yapılan karşılaştırmalarda alternatif olarak geliştirilen parti büyüklüğü belirleme yöntemlerden iyi sonuç vermediği bildirilmiştir. Daha iyi sonucun ise yapay sinir ağlarında gizli katman sayısı, düğüm sayısı gibi [5] faktöre bağlı olabileceği bildirilmiştir. Bu tez çalışmasında ise işaret edilen faktörlerin değişik varyasyonları denenmiştir.

Yapay sinir ağlarının performansları Periyodik Sipariş Miktarı Yöntemi, Parçalı Dönem Dengesi Yöntemi, En Düşük Birim Maliyet, En Düşük Toplam Maliyet, Silver-Meal parti büyüklüğü belirleme yöntemleri ile karşılaştırılmıştır. Karşılaştırma optimum çözüm (Wagner-Whitin) sapmaları hesaplanarak yapılmıştır. Yapay sinir ağları NeuroSolutions 4 programı kullanılarak oluşturulmuş ve yine NeuroSolutions 4 vasıtası ile yapay sinir ağlarının eğitimi ve veri üretim işlemleri gerçekleştirilmiştir. Yapay sinir ağlarının sipariş büyüklüklerini elde etmek amacı veri üretim işlemi gerçekleştirilmiştir. Veri üretim işleminde hangi verilerin kullanılacağının belirlenmesi amacı ile Analitik Hiyerarşi Prosesi kullanılmıştır. Yapay sinir ağlarının ve parti büyüklüğü yöntemlerinin karşılaştırmasında sadece toplam maliyet kriterine göre değil sipariş planlarına göre ve tutarlılık oranlarına göre de karşılaştırılmıştır. Çalışma uygulama ağırlıklıdır. Ayrıca çalışmada gerçek veriler kullanılmış olup verilerin alındığı sistem halen canlı ve aktiftir. Karşılaştırmalarda toplam maliyet karşılaştırma kriteri olarak kullanılmıştır. Wagner-Whitin çözümü en uygun çözüm olarak kabul edilmiştir. Genel olarak toplam maliyet açısından en iyi performansı veren ağın özellikleri aranmıştır. Test verileri eğitim verileri arasında rastgele seçilmiştir. Ağların performanslarının artırılmasına yönelik; gizli katman sayısının, düğüm sayısının artırılması gibi yöntemler uygulanmamıştır. Çalışma sonucunda SM algoritmasının performansından daha iyi performans gösteren yapay sinir ağı tabanlı metot elde edilmiştir.

1. BÖLÜM

ÖNCEKİ ÇALIŞMALAR

Bu bölümde tez çalışmasında kullanılan bilimsel metotlara ilişkin literatür taraması sunulacaktır. Tez çalışması kapsamında parti büyüklüğünün belirlenmesi amacı ile yapay sinir ağları kullanılmaktadır. Bu kapsamda ilk etapta parti büyüklüğü hakkında yapılan önceki çalışmalar özet olarak sunulacaktır. Yapay sinir ağlarının eğitimi esnasında eğitim, test ve veri üretimi işlemlerinde kullanılacak verilerinin seçiminde Analitik Hiyerarşi Prosesi kullanılmıştır. Analitik Hiyerarşi Prosesi ikinci bölümde sunulacaktır. Yapay sinir ağlarına ilişkin önceki çalışmalar ise üçüncü aşamada sunulacaktır. Son aşamada ise parti büyüklüğü belirleme probleminde yapay sinir ağları kullanılarak yapılan çalışmalar sunulacaktır.

I. Parti Büyüklüğü Belirleme

Parti büyüklüğü belirleme problemi literatürde oldukça yoğun ilgi çekmiştir. En uygun çözüm Wagner ve Whitin tarafından 1958 yılında geliştirilmiş, taleplerin elde bulundurma, hazırlık ve stok maliyetlerin sabit olarak kabul edilen N dönemli tek ürünlü tek aşamalı dinamik parti büyüklüğü problemleri için bir en uygun çözümü sağlayan matematiksel algoritma geliştirilmiştir. Wagner ve Whitin tarafından geliştirilen bu algoritma en uygun çözüm olmasına rağmen anlaşılırlığının zor olması ve sayısal olarak karmaşık olması nedeniyle Silver Meal, LaForge ve Peterson tarafından eleştirilmiştir [5].

Tunalı S. ve Goren H.G. tarafından yapılan parti büyüklüğü probleminde genetik algoritma uygulamalarının gözden geçirilmesi [6] konulu çalışmada 2008 öncesi

araştırmalar uygulanan parti büyüklüğü probleminin yapısına göre Şekil 2.1. deki gibi tasniflendirilmiştir.

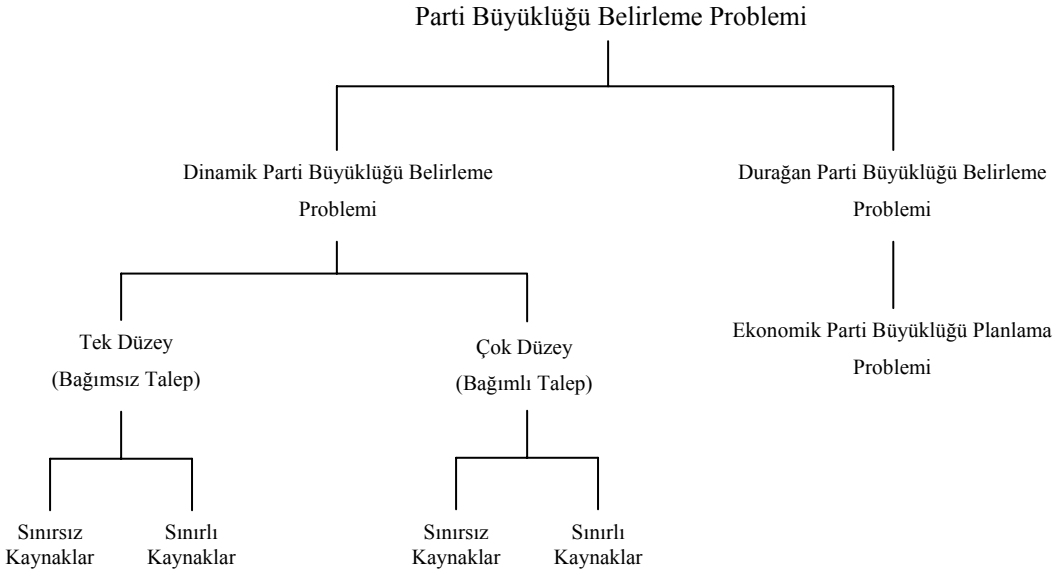

Şekil 1.1. Parti Büyüklüğü Belirlemenin Sınıflandırılması [6].

Durağan parti büyüklüğü belirleme probleminde gelecek dönemlerdeki talebin bilindiği ve üretim miktarının bilindiği varsayılır. Tek bir makinede hazırlık maliyetleri ve elde bulundurma maliyetleri en aza indirilmesi amaçlanır. Dinamik parti büyüklüğü belirleme problemi ise sonlu planlama ufkunda dinamik talep ile ilgilenir. Çok düzey parti büyüklüğü belirlemesinde bileşen ailesi ilişkisi vardır. Bir düzeyin çıktı elemanları diğer bir düzeyin girdileri olabilir [6].

Ekonomik Parti Büyüklüğü Belirleme problemi 1978 yılında Elmaghraby tarafından pek çok farklı elemanın aynı olanaklar ile tekrar eden esaslarda planlanması olarak tanımlanmıştır. Böylece ekonomik parti büyüklüğü belirleme problemi sabit talep ve sonsuz planlama ufkunda tek düzeyli çok elemanlıdır denebilir. Dinamik parti büyüklüğü belirleme problemi ise kaynak sınırı olmayan tek elemanlı tek düzeyli olarak Wagner ve Whitin tarafından çözülmüştür [6].

Üretimin tek düzeyli olduğu ve kaynakların sınırsız olduğu varsayılan dinamik parti büyüklüğü problemi Zangwill tarafından ele alınmıştır. Söz konusu çalışmada Wagner ve Whitin'in algoritmasına benzer ancak yok satma durumunun da dâhil edildiği algoritma üzerinde durulmuştur. Çözümün baştan sona veya sondan başa doğru yapılabildiği belirleyici üretim planlaması modeli geliştirmiştir [7],[8].

Üretimin tek düzeyli olduğu ve kaynakların sınırlı olduğu varsayılan dinamik parti büyüklüğü öncü çalışmayı Lambrech ve Van der Eecken 1978 yılında tek aşamalı, tek ürünlü kısıtlandırılmış parti büyüklüğü problemlerinin çözümü için sezgisel bir metod olarak geliştirmişlerdir. Bu çalışmayı 1981 yılında Dixon ve Silver çalışması takip etmiştir [9].

Üretimin çok düzeyli olduğu ve kaynakların sınırsız olduğu varsayılan dinamik parti büyüklüğü problemi 1973 yılında Crowston ve Wagner bazı sezgisel metotların optimal çözüme yakın sonuç verdiklerini ispatlamışlardır, 1974 yılında ise çok aşamalı montaj sistemleri için dinamik parti büyüklüğünün belirlenmesine yönelik dal sınır tekniğini kullanan diğer bir algoritma geliştirmişlerdir [6].

Üretimin çok düzeyli olduğu ve kaynakların sınırlı olduğu varsayılan dinamik parti büyüklüğü Steinberg ve Napier tarafından 1980 yılında kısıtlandırılmış tek ürünlü çok aşamalı parti büyüklüğü problemlerini şebeke problemi olarak formüle edilmiştir [6].

E.H.L. Aarts tarafından 2000 yılında yayınlanan makalede parti büyüklüğü belirleme probleminde çevrim içi ayrışma yaklaşımı uygulanmıştır. Ayrışma yaklaşımı Wagner Whitin ekonomik parti büyüklüğü belirleme probleminin çevrim içi sınıfı için sunulmuştur. Ayrışma, en uygun planın, yeniden üretim noktasında ve iki yeninden üretim noktasında planın üretimin kalan kısmından bağımsız olduğu gerçeğine dayandırılmıştır. Bunun için ayrışma yaklaşımının iki özelliğinden faydalanılmıştır: ilki, sonraki yenileme noktasının tahmini, ikincisi bu noktaya kadar optimal planın belirlenmesi. Sonraki yenileme noktasının tahmini yapay sinir ağları ile veya istatistiksel sınıflama metodu ile yapılabileceği ifade edilmiştir [10].

Söz konusu araştırma çevrim içi parti büyüklüğü belirleme problemi için talebin karakteristiğinden, maliyet hesaplamasından ve gelecekteki talebin miktar bilgisinden muaf, yeni bir yaklaşım olarak sunulmuştur. Bu yaklaşım optimal çözümün özelliklerini tahminini temel alan böl ve ele geçir metodunu takip etmiştir. Parti büyüklüğü belirleme problemi için plan en uygun planın alt planlara bölündüğü yenileme noktası tarafından karakterize edilmiştir. Her bir alt plan için üretim miktarı diğer alt planlardan bağımsız olarak belirlenmiştir. Sunulan çalışmada üç maliyet yapısı göz önüne alınmıştır. İlk maliyet yapısı standart Wagner Whitin maliyet yapısıdır. Diğer iki maliyet yapısı her zaman periyodu için üretim kapasitesinin sınırlandırılması, ikinci maliyet yapısı kapasite limitinin aşılması için fazla mesai üretiminin kullanılmasının mümkün olduğu durum, üçüncü maliyet yapısı ise dış kaynak kullanımının mümkün olduğu durum olarak belirlenmiştir. Sonraki yenileme noktasının hesaplanması için çok katmanlı yapay sinir ağları kullanılmıştır. Çok katmanlı ağın eğitiminden önce, ön işlem adımı olarak bütün girdi elemanları ve hedef vektörleri 0 ve 1 arasında ölçeklendirilir. Bu durum sigmoid tepki fonksiyonunun, benzer ağırlık, benzer başlangıç yöntemleri ve tüm durumlarda benzer öğrenme parametre değerlerinin kullanılmasına imkan tanımıştır. Sonra ölçeklendirilmiş maliyet hedef vektör elemanlarına $x \to 1 - x$ değişimi değişiminin uygulanması ile maliyet hedef vektörü ve sıfır bir arasında yeniden ölçeklendirilmiştir. Çok katmanlı ağların başlangıçtaki ağırlıkları [-1,1] arasında düzgün dağılım formundadır. Ağırlık güncelleme dizisini temel alan sıralı gradyant azalan öğrenme oranı $\eta = 0.1$ ve momentum dönemi $\mu = 0.9$ uygulanan geri yayılım algoritması ile ağırlıklar güncellenmiştir. Çok katmanlı ağ için 2500000 tekrarlıdır. Önceden belirlenmiş ağ topolojisi kullanılmıştır. Bütün ağlar bir gizli katmana sahiptir. Her beş farklı ağ topolojisi için eş 10 ağ kullanılmış ve başlangıç ağırlıklarını rastgele atanmıştır. Eğitim seti her ağ için rastgele sunulmuştur [10].

Aarts ve arkadaşları ele alınan tüm maliyet yapıları için tümüyle değişim noktaları yakalamıştır. Veri ufku uzunluğu tümüyle değişim noktasından daha küçük olduğu zaman MLP tabanlı değişken ufuk politikası en iyi sonucu sunmuştur. Veri ufkunun uzunluğu kısa, değişken olan talep ise büyüktür. Çok katmanlı yapay sinir ağı tabanlı değişken ufuk politikası diğer politikaların hepsini bastırmıştır [10].

Lotffi K.Gaafar, M.Hisham Choueiki 2000 yılındaki çalışmalarında zaman değişimli talep deseni sunulan belirli durumlar için parti büyüklüğü probleminin çözmek için yapay sinir ağı modeli geliştirmişlerdir. Yapay sinir ağı, Waghner-Whitin algoritmasından elde edilen optimum sipariş deseni kullanılarak eğitilmiştir. Gürültüyü filtrelemek ve planlama ufkundaki tahmin edilen taleplerin karşılaştırılan sipariş miktarını güvenceye almak için özel bir çıktı kodu kullanılmıştır. Dönemsel sipariş miktarı (POQ), MINS, ve Silver-Meal (SM) yöntemlerinin ortalama yüzdeleri ile yapay sinir ağı bütün test durumlarına gürbüz(robust) performans göstermiştir. Böylece doğru bir şekilde geliştirilmiş yapay sinir ağı modeli parti büyüklüğü çözümüne geçerli bir alternatif sağladığı değerlendirilmiştir. Bu çalışmada aynı zamanda planlama ufku ve talep desenindeki değişimler ile ilgili olarak POQ, MINS ve SM parti büyüklüğü algoritmalarının bir incelemesi sunulmaktadır. İncelenen durumlar için, üç algoritmanın performansı, seçilen iki faktörden etkilendiği, MINS ve SM algoritmaları POQ dan daha iyi performans gösterdiği ifade edilmiştir. MINS ve SM algoritmalarının POQ algoritmasına üstünlüğü pratik olarak önemsiz olduğu değerlendirildiğinden en basit yaklaşım kullanılmıştır. Araştırma sonuçları en uygun sipariş düzeninin üretilmesinde Yapay sinir ağlarının başarı göstermesine rağmen, en iyi maliyet performansı yapay sinir ağını en uygun maliyet ile eğiterek elde edilebileceğini ifade edilmiştir. Yapay sinir ağının en iyi maliyet performansı gösterebilmesi için; çıktı katmanından sonra, maliyetin çıktı katmanında tanımlanmış parti büyüklüğü belirleme fonksiyonu gibi bir hesaplama katmanı ilave edilerek başarılabileceği değerlendirilmiştir[5].

Mikio Kubo ve arkadaşları 2005 yılında yayınlanan çalışmalarında parti büyüklüğü belirlemenin, üretim planlamada ki uygulamalar ile tümleşik ve en uygun şekle sokma problemlerinin bir türü olduğu belirtilmiştir. Bu tip problemlerde sabit sayıdaki dönemde ve öğelerin üretim planındaki makinelerde gerçekleştiği ve bir makinenin üretime başlamak için doğru bir şekilde hazırlanması gerektiğinden hazırlıklardaki düşmenin, sabit maliyetlerdeki ödeme veya makine çalışma zamanlarının düşmesi anlamına geldiği ifade edilmiştir. Ayrıca belirlenmiş bir dönemdeki üretilen miktar, bu dönemlerdeki talepleri karşılamak veya stokta bekletilmek için kullanılabildiği, üretimin

önceki dönemlerin taleplerin karşılamaya alışık olduğu zaman, model geciktirmeye (backlogging) müsaade edilebileceği belirtilmiştir [11].

Kubo ve arkadaşları tarafından yapılan çalışmanın amacı parti büyüklüğü belirleme problemi için hibrit özellikte yasak arama stratejisi (tabu search strategy) geliştirmektir. Söz konusu hibrit strateji ile farklılığa zorlanan yasak arama bünyesi içinde gevşek ve sıkı (relax and fix heuristic) sezgisel yöntemlerin kalitesinin kıymetlendirilmesine müsaade edilebileceği ifade edilmiştir. Çalışma sonuncunda geliştirilen stratejinin karşılaştırılan diğer sezgisel yöntemlere göre bazı avantajları olduğu değerlendirilmiştir. Geliştirilen strateji gevşek ve sıkı sezgisel yöntemi ve zaman kısıdı olan dal sınır yöntemlerinin versiyonları ile karşılaştırılmıştır [11].

Megala N., Jawahar N. 2005 yılındaki çalışmasında ıskonto fiyat yapısı ve kapasite sınırı ile dinamik parti büyüklüğü belirleme problemi ele alınmıştır. Her ne kadar iyi bilinen Wagner-Whitinin dinamil programlaması Tek düzey parti büyüklüğü belirleme probleminin en uygun çözümünü sağlama yeteneğinde olsa da yöntemin yüksek hesaplama karmaşıklığına göz yumduğu gerekçesi ile eleştirmiştir. Genellikle büyük boyutlardaki pratik problemlerde, dinamik programlamanın kullanımını sınırlandığı belirtilmiştir. Çözümlerini, Genetik algoritma ve Hopfield yapay sinir ağını çözüm kalitesi ve hesaplama süresi arasındaki dengeyi kurmak üzere tasarlamışlardır. Dinamik programlamanın deneysel problemlere en uygun çözümü türetmek üzere modellendiği belirtilmiştir. Hopfield yapay sinir ağının ve genetik algoritmanın uygunluğu, dinamik programlamadan sapma yüzdeleri karşılaştırılarak belirlenmiştir. Çalışmada, dinamik parti büyüklüğü belirleme problemi, ıskonto fiyat yapısı ve kısıtlandırılmış depolama kapasitesi altında modellenmiştir. Sayısal çalışma göstermiştir ki genetik algoritma çeşitli hacimdeki problemler için yeterli sonuçlar üretebilir yetenekte olduğu, Hopfield yapay sinir ağı ise küçük hacimdeki problemler için yeterli sonuçlar üretebildiği ancak büyük hacimdeki problemler için daha düşük sonuçlar verdiği gözlenmiştir. Deneyin, Hopfield yapay sinir ağı modelinin çok fazla kontrol parametresi içermesi gerektiği izlenimini uyandırdığı not edilmiştir. Ayrıca Hopfield yapay sinir ağı kontrol parametrelerinin ayarlanması ve Hopfield yapay sinir ağının Boltzman makinesi ile birleştirilmesi halinde üretilen çözümün geliştirebileceği değerlendirilmiştir [12].

Radzi N.H.M. ve arkadaşları tarafından matematiksel veya sezgisel yaklaşımlara dayanan pek çok algoritma geliştirildiği, yapay sinir ağları üretim planlama dahil pek çok alanda araştırmacıların dikkatini çekmesi nedeniyle yapılan çalışmada tek düzeyli parti büyüklüğü problemi çözümüne yapay sinir ağları kullanıldığı bildirilmiştir. Çalışmada sezgisel teknikler olan dönemsel sipariş miktarı, parti için parti ve Silver Meal gibi metotlara dayanan üç model geliştirilmiştir. Planlama periyodu 12 dönemde de değişkenlik arz eden ancak belirli olan talepleri içermektedir. Model MatLab yazılımı kullanılarak geliştirilmiştir. Geri yayılımlı öğrenme algoritması ve ileri beslemeli çok katmanlı ağ mimarisi seçilmiştir. Sonuçlar; üç modelin en iyi çözümü verebileceğini ve parti büyüklüğü belirleme problemine uygulanmasının kolay olacağını gösterdiği bildirilmiştir. Çalışma sonucunda; yapay sinir ağlarının parti büyüklüğü belirleme problemine uygulanabileceği, daha iyi ve daha hızlı sonuç verebileceğini göstermiştir. Yapay sinir ağlarının problemin gerçek formunun derin bilgisine ihtiyaç duyulmadan devam eden fonksiyonun tahmin edilmesine kullanılabildiği bildirilmiştir. Bu yüzden parti büyüklüğü belirleme problemi daha hızlı ve kolay çözülebileceği öne sürülmüştür. Yapay sinir ağı ile herhangi bir hatırlamaya ve özel girdi örüntüsüne bağlı olmadığından değişik girdi desenleri kullanılabileceği, bilgiler anlamlı formda sunulabileceği ve daha iyi modeller geliştirilebileceği değerlendirilmiştir. Bunun yanında, yapay sinir ağları kümeleme amacı ile kullanılabileceği ifade edilmiştir. Çalışmanın uygulama kısmında ise ileri beslemeli çok katmanlı ağ kullanılmıştır. Girdi olarak 12 dönemlik talep kullanılmıştır. Ayrıca elde bulundurma maliyeti ve tekrar sipariş verme maliyeti de girdi olarak sunulmuştur. Girdiler normalize edilmiştir. Her üç parti büyüklüğü belirleme yöntemi için 63 farklı model oluşturulmuştur. Her bir yöntemdeki yapay sinir ağı MatLab programının sunmuş olduğu hata kareler ortalamasına göre karşılaştırılmıştır [13].

II. Yapay Sinir Ağları

Sinirsel hesaplamanın tarihi pek çok yayıncı tarafından tartışılmıştır. Hesaplama alanının başlangıç döneminde hesaplamanın ne olması gerektiği hakkında karşıt iki felsefi bakış açısı oluşmuştur. Bunlardan ilki beyin bilgisayar gibi sembol işleme sistemidir ve hesaplamanın amacı beynin hesaplama yeteneğinin sunulması, ikinci

amacı ise beynin yapısını model olarak almasıdır. Sinirsel hesaplama ikinci düşünceyi takip etmektedir [2].

McCulloch ve Pitts 1943 yılında yapay sinirlerin ilk teorik modellerinden biri olan M-P sinir hücresini (McCulloch- Pitts sinir hücresi) tanıtmışlardır. M-P sinir hücresi ikili (0,1) girdileri, 0 veya 1 değerinde olacağı varsayılan çıktıları ve içsel eşik düzeyini karakterize eder. Bu gibi işlemlerde şayet toplam girdi eşik düzeyine büyük eşit ise sinir hücresi çıktısı bir tanedir. M-P sinir hücrelerinin her bir birine bağlı olduğu durumda yapay sinir ağı denebileceğini belirtmişlerdir. Aslında, yapay sinir hücrelerini kullanan hesaplama modeli, fizyoloji ve Turing'in hesaplama kuramına dayanmaktadır. Her hangi bir hesaplanabilir fonksiyonun sinir hücrelerinden oluşan ağlarla hesaplanabileceğini ve mantıksal "ve/veya" işlemlerinin gerçekleştirilebileceğini bu iki araştırmacı tarafından ispatlanmıştır. McCulloch ve Pitts bu ağ yapılarının uygun şekilde tanımlanmaları halinde öğrenme becerisi kazanabileceğini de ileri sürmüşlerdir [14].

Hebb 1949 yılında öğrenme gerçekleşmesi halinde sinir hücreleri arasındaki bağın güçleneceğini ileri sürmüştür. Hebb iki sinir hücresinin arasında eş zamanlı hareketin olması durumunda aralarındaki bağlantının daha güçleneceğini değerlendirmiştir [15].

Yapay sinir ağları alanındaki ilk konferans Kanada'nın Dortmouth şehrinde 1956 yılında düzenlenmiştir. İlk sinir hücresi hesabı alanındaki araştırma projesi Rosenblatt tarafından 1958 yılında düzenlenmiştir. Rosenblatt M-P sinir hücreleri ayarlanabilir güçlükteki bağlantılar ile irtibatlı ise örüntü sınıflandırması yapmak üzere eğitimin olabileceğini söylemiştir. Bu tip ağlar, yapay sinir ağı "percoptron" olarak adlandırılmıştır. Sonraki yıllarda araştırmacılar tarafından McCulloch ve Pitts'in çalışmaları Hebb'in varsayımı ile birleştirilmiştir. Yapay sinir ağları sınırlandırılmış genellemeler ve girdinin gürültülü olduğu zaman bile sınıflandırmalar yapabilmektedir. Yapay sinir ağları girdi katmanı, gizli katman ve çıktı katmanından oluşmaktadır. Başlangıçta bütün bağlantıların ağırlığı, verilen girdiye gelişi rastgele üreten gelişi güzel değerler olarak atanır. Ağırlıklar arzu edilen çıktıyı üretmek için eğitim esnasında ayarlanır [2].

Widrow ve Hoff 1960 yılınnda ADALINE (Adaptive Linear Element) öğrenme algoritmasını geliştirmiştir. Adaline bir yapay sinir ağı türü olup, basit sinir hücresi benzeri birimlere dayanır [16].

Adaline iki katmanlı versiyonu olan M-Adaline (Multiple ADALINE) 1962 'de ortaya çıkmıştır. Adaline ve Madaline hava tahmini, karakter tanıma, konuşma tanıma ve uyarlanabilir kontrolü içeren birçok uygulamada uygulanabilmiştir Minsky ve Papert 1969 yılında algılama (perceptions) isimli yapay sinir ağlarının önemli gözden geçirmesini yayınlamışlardır. Tek katmanlı yapay sinir ağlarının liner olmayan ayrılabilir problemleri çözemediğini göstermişlerdir. Bu nedenle yapay sinir ağları alanındaki çalışmalara duraklama dönemine girilmiştir. Bu duraklamaya rağmen az da olsa bir takım çalışmalara devam edilmiştir [2].

Grossberg 1976 yılında sinirsel hesaplama modelinden ilham alınmış olan ART'yi (Adaptive Resonannce Theory) geliştirmiştir [2].

Kohonen 1982 yılında SOM (Self Organising Feature Map) sunmuştur. Bu model, bir girdi uyarıcısına cevap vermek için unsurların yarıştığı ve bu girdiye daha güçlü cevap vermek için kazananın kendini adapte ettiği karşılaştırmalı öğrenme prensibine dayanmaktadır. Ağın iç organizasyonu sadece girdi uyarıcısına bağlı iken bu öğretmensiz öğrenme süreci ile sonlanır [17].

Hopfield 1982 ve 1984 yılları arasında Hopfield modelini geliştirerek yapay sinir ağları alanında çalışmalara kıvılcım çakmıştır. Bu model en küçük enerjiyi arayan ve bağlantılarında bilgi depolayan, birbirleri ile bağlı işlem elemanlarından oluşmaktadır [18].

Boltzmann makinesi 1985 yılında Ackley ve arkadaşları tarafından geliştirilmiştir. Boltzman makinesi simule edilmiş sertleştirme isimli bir araştırma metodunu kullanır [19].

Rumelhart ve arkadaşları 1986 yılında günümüzde en yaygın olarak kullanılan geri yayılım algoritmasını geliştirmiştir. Öğrenme süresi boyunca ağırlıkların geri yayılımlı

olarak güncellenmesine imkân kılar. Ayrıca geri yayılım öğrenme kuralı ağırlıkların gizli katmanlarda başarılı bir şekilde ayarlanmasını mümkün kılar [2].

III. Analitik Hiyerarşi Prosesi

Analitik Hiyerarşi Prosesi (AHP) İlk olarak Myers & Alpert [20] tarafından 1968 yılında ortaya atılan ve daha sonra 1977 yılında Thomas L. Saaty tarafından geliştirilen çok ölçütlü karar verme tekniklerinden biridir. AHP karar almada, grup veya bireyin önceliklerini de dikkate alan, nitel ve nicel değişkenleri bir arada değerlendiren matematiksel bir yöntemdir.

Karar verme problemlerinde insan yargılarının kullanımı son zamanlarda dikkat çeken bir ölçüde artmıştır. AHP ile karar vericilerin farklı psikolojik ve sosyolojik durumlardaki gözlemleri de dikkate alınarak kendi karar verme mekanizmalarını tanıma olanağı sağlanmaya çalışılmaktadır. Bu yöntemle karar vericilerin daha etkin karar vermeleri amaçlanmıştır [21].

AHP'de karar vericinin amacı doğrultusunda faktörlerin ve faktörlere ait olan alt faktörlerin belirlenmesi ilk adımdır. AHP'de öncelikle amaç belirlenir ve bu amaç doğrultusunda amacı etkileyen faktörler saptanmaya çalışılır, bu aşamada karar sürecini etkileyen tüm faktörlerin belirlenebilmesi için anket çalışmasına veya bu konuda uzman kişilerin görüşlerine başvurulabilir.

Amaç, faktör ve alt faktörler belirlendikten sonra, faktör ve alt faktörlerin kendi aralarındaki önem derecelerinin belirlenmesi için ikili karşılaştırma karar matrisleri oluşturulur. Bu matrislerin oluşturulmasında Saaty [21] tarafından 1968 yılında önerilen 1-9 önem skalası kullanılır.

Saaty 1980 ve 2000 yılında ki çalışmalarında olduğu gibi analiz sonunda verilecek karar birçok kişiyi etkileyecek yapıda ise ikili karşılaştırma karar matrisleri farklı kişilerin yargılarının birleştirilmesi ile oluşturur. Tutarlı ikili karşılaştırma matrisleri elde edebilmek için, geometrik ortalama yöntemi kullanılır, Saaty tarafından önerilen yöntem 1-9 önem skalası en iyi sonuçların elde edilmesini sağlamaktadır [22],[23].

2. BÖLÜM

YÖNTEM VE MATERYAL

I. Materyal

Tez çalışmasının uygulanması, Kayseri ilinde konuşlu bulunan imalat ve otomotiv sektöründe faaliyet gösteren X firmasında gerçekleştirilmiştir.

Tesis kurulduğu yıldan beri geniş bir ürün yelpazesinde üretim yapmaktadır. Aynı zamanda özel tip teçhizatların bakım onarımını yapmaktadır. Ayrıca ülke ekonomisinin gelişmesine paralel olarak imalat faaliyetlerini uçak malzemelerinin imalatına kaydırmıştır. Bakım onarımı yapılan teçhizatların ve imalatı yapılan malzemelerin miktarının seri üretime uygun olmaması ve geniş üretim, bakım/onarım yelpazesi nedeniyle sipariş üzerine yapmaktadır.

II. Yöntem

Bu bölümde tez çalışmasında kullanılan bilimsel metotlar hakkında bilgi verilecektir. İlk bölümde parti büyüklüğü belirleme problemi hakkında ikinci bölümde yapay sinir ağları hakkında, üçüncü bölümde ise Analitik Hiyerarşi Prosesi (AHP) hakkında bilgilendirme yapılacaktır.

A. Parti Büyüklüğü Belirleme Problemi

Malzeme ihtiyaç planlamasında önemli konulardan birisi de parti büyüklüğünün belirlenmesidir. İşletmenin üretimde kullandığı hammadde ve yarımamül ihtiyaçlarının, tüm yılı kapsayacak şekilde hesaplanması gerekir. Yani başka bir deyişle parti büyüklüğünün belirlenmesi gerekmektedir. Belirlenen parti büyüklüğü planlama

döneminin kapsayacağı sürede ortaya çıkacak olan tüm talepleri kapsaması gerekmektedir. Parti büyüklüğü planlama ufkundaki talepleri karşılarken toplam maliyeti en düşük seviyeye düşürülmesi ve nihai ürün için gerekli olan bileşenleri kapsamlıdır.

Parti büyüklüğü belirleme yöntemleri, sadece hazırlık ve elde bulundurma maliyetlerini kullanıyor ve kaynaklar ile ilgili herhangi bir kısıt içermiyorsa bu tür yöntemler kaynak kısıtlaması olmayan parti büyüklüğü belirleme yöntemleri olarak adlandırılırlar. Parti büyüklüğü belirleme yöntemleri, hazırlık ve elde bulundurma maliyetleri ile birlikte kaynaklar ile ilgili kısıtları içeriyorsa bu tür yöntemler kaynak kısıtlaması olan parti büyüklüğü belirleme yöntemleri olarak adlandırılırlar [24].

Parti büyüklüğü belirleme yöntemlerini statik ve dinamik olarak iki grupta toplamak mümkündür. Statik parti büyüklüğü, bir kere hesaplandıktan sonra planlama dönemi boyunca değişmeyen bir büyüklüktür. Dinamik parti büyüklüğü ise, net ihtiyaç verilerindeki değişmelere paralel olarak ayarlanabilir.

Şenyiğit E. tarafından parti büyüklüğünün belirlenmesi amacı yeni bir sezgisel algoritma konulu çalışmada, MRP sistemlerinde en çok kullanılan parti büyüklüğü belirleme yöntemlerini belirlenmiştir [25]. Bu yöntemler aşağıda belirtilmiştir.

1- EOQ: (Period Order Quantity) Ekonomik Sipariş Miktarı
2- PPB: (Part Period Balancing) Parçalı Dönem Dengesi Yöntemi
3- LUC: (Least Unit Cost) En Düşük Birim Maliyet Yöntemi
4- LTC: (Least Total Cost) En Düşük Toplam Maliyet Yöntemi
5- S-M: (Silver-Meal) Silver-Meal Yöntemi
6- W-W: (Wagner-Whitin) Wagner-Whitin Yöntemi

Bundan sonraki bölümde yukarıda belirtilen parti büyüklüğü belirleme yöntemleri hakkında bilgi verilecektir.

1. Ekonomik Sipariş Miktarı (EOQ- Economic Order Quantity)

Ekonomik sipariş miktarı politikası, malzeme ihtiyaç planlama sisteminde kullanılmak üzere geliştirilmemiştir. Ancak kolaylıkla bu sisteme de uygulanabilecek bir yapıya sahiptir.
Burada;

T :Model ufku

d_t : t dönemdeki talep $(t = 1,.....T)$

K :Hazırlık maliyeti

h :Elde bulundurma maliyeti

x_t : $t$dönemdeki üretim miktarı $(t = 1,.....T)$

I_t : t dönemde kalan stok $(t = 1,.....T)$

Yukarıdaki tanımlar ışığında ekonomik sipariş miktarı Heuvel W. ve arkadaşlarının 2007 de yapmış oldukları çalışmada aşağıda olduğu gibi modellenmiştir [26].

Amaç fonksiyonu formül 3.1. de olduğu gibidir.

$$C^*(d,T) = \min \sum_{t=1}^{T} (K\delta(x_t) + hI_t) \qquad 3.1.$$

Kısıtlar ise formül 3.2. , 3.3. ve 3.4. de olduğu gibi ifade edilebilir.

$$\text{s.t.} \quad I_t = I_{t-1} - d_t + x_t \qquad (t = 1,.....T) \qquad 3.2.$$

$$x_t, I_t \geq 0 \qquad (t = 1,.....T) \qquad 3.3.$$

$$I_t = 0\,, \qquad 3.4.$$

Formül 3.5. gösterildiği gibi x=0 olması durumunda $\delta(x)$=0 olacak x>0 ‘dan büyük olması durumunda ise $\delta(x)$=1 olacağı ifade edilmiştir.

$$\delta(x) = \begin{cases} 0.....x = 0 \\ 1.....x > 0 \end{cases} \qquad 3.5.$$

2. Parçalı Dönem Algoritması (PPB- Part Period Balancing)

Bu yöntem, sipariş büyüklüğünü belirlerken toplam sipariş verme maliyetini elde bulundurma maliyetine eşitlemeye çalışır. Bunun için formül 3.8.'de hesaplanan ekonomik parça dönem faktörü kullanılır. Bu faktör ile denklem 3.9.'da hesaplanan kümülatif birim zamanda elde bulundurulan ürün miktarı ile karşılaştırılır [27].

EPDF : Ekonomik Parça Dönem Faktörü
T :Model ufku
D :Sipariş verme sayısı X=1,2,...T
X :Stokta tutulan toplam ürün miktarı
SBD :Siparişte beklenen dönem,
C_s : Sipariş Maliyeti (pb/sip),
C_h : Bir birimi 1 yıl elde bulundurma maliyeti
P : Birim satın alma maliyeti
R_k : k.dönemdeki talep oranı

Sipariş maliyeti formül 3.6'da olduğu gibi ifade edilebilir.

$$C_s = PC_h \sum_{k=1}^{T} (k-1)R_k \qquad 3.6.$$

Ekonomik parça dönem faktörü formül 3.7. olduğu eşitliğin diğer tarafına alınabilir.

$$\sum (k-1)R_k = \frac{C_s}{PC_h} \qquad 3.7.$$

Ekonomik parça dönem faktörü formül 3.8.' de olduğu gibi yazılabilecektir.

$$EPDF = \frac{C_s}{PC_h} \qquad 3.8.$$

Kümülatif birim zamanda elde bulundurulan ürün miktarı formül 3.9.'daki gibidir.

KBEÜM=SBD *D. 3.9.

KBEÜM değeri EPDF değerini geçtiği dönemde, bu döneme kadar olan talep büyüklüğünde sipariş verilir. Bu yöntemde planlanan dönemlerin talepleri EPDF değerine yaklaşıncaya kadar tek bir sipariş altında toplamaya çalışır [27].

3.En Düşük Birim Maliyet Yöntemi (LUC-Least Unit Cost)

Bu yöntem önce ilk dönemin net ihtiyacı kadar sipariş verilmesi durumunda birim maliyetin ne kadar olacağını hesaplar. Daha sonra bir sonraki dönemin net ihtiyacı sipariş miktarına ilave ederek birim maliyeti yeniden hesaplar. Birim maliyet düşmeye devam ettikçe bir sonraki dönemlerin net ihtiyaçları sipariş miktarına ilave edilir. Birim maliyet artmaya başladığında durulur. Birim maliyeti arttıran dönemden önceki dönemlerin net ihtiyaçlarını toplamı sipariş miktarını oluşturur. Birim maliyetin arttığı dönem başlangıç olarak alınarak daha önceki işlemler tekrarlanır. Bu yöntemde karar kriteri birim başına en düşük maliyettir. Birim maliyet denklem 3.11.'de belirtildiği gibi hesaplanır [27].

En düşük birim maliyet Silver-Meal yöntemine benzer. Dönemlik ortalama maliyetler yerine birimlik ortalama maliyetleri esas alır. Ortalama birim maliyetin ilk artış gösterdiği dönem tekrar sipariş verilir. Tüm planlanan zaman boyunca işlem devam ettirilir [28].

C_s : Sipariş Maliyeti (pb/sip)

BM : Birim maliyet

C_h : Bir birimi bir yıl elde bulundurma maliyeti

P : Birim satın alma maliyeti

R_k : k.dönemdeki talep oranı

$TRC(T)$: T dönemleri boyunca toplam ilgili maliyet

T : Dönemlerdeki tekrar doldurmalar için gerekli süre

$$\frac{TRC(T)}{\sum_{k=1}^{T} R_k} = \frac{\text{C + T.dönem sonuna kadar elde tutma maliyeti}}{\sum_{k=1}^{T} \text{R}_k} \qquad 3.10.$$

Formül 3.10 dan hareketle birim maliyet formül 3.11. deki gibi ifade edilebilir [28].

$$BM = \frac{C + Ph\sum (k-1)R_k}{\sum_{k=1}^{T} R_k} \qquad 3.11.$$

4. En Düşük Toplam Maliyet Yöntemi (LTC-Least Total Cost)

Bu yaklaşımda kullanılan ana varsayım şöyledir: planlama dönemindeki tüm partiler için hazırlık ve elde bulundurma maliyetleri toplamının minimize edilmesi için, partilerin toplam maliyetlerinin birbirine eşit olması gerekmektedir. En düşük toplam maliyet yaklaşımı bu amaca ulaşmak için, birim başına hazırlık maliyeti ile elde bulundurma maliyetlerinin eşit olduğu miktarlarda sipariş verir. Bu yaklaşım, maliyetlerin eşitliğini sağlamak için ekonomik parça-dönem faktörü (EPDF) olarak tanımlanan bir araçtan yararlanır. Ekonomik parça-dönem faktörü, stokta bir dönem elde bulunduruldu zaman, hazırlık maliyetine eşit elde bulundurma maliyeti verecek olan birim miktarı olarak tanımlanır. Formül 3.12'de ki gibi ifade edilir [29]

Cs :Sipariş Maliyeti

Ch :Elde bulundurma maliyeti

P : Birim satın alma maliyeti

C_h : Bir birimi 1 yıl elde bulundurma maliyeti

P : Birim satın alma maliyeti

$TRC(T)$: T dönemleri boyunca toplam ilgili maliyet

T : Dönemlerdeki tekrar doldurmalar için gerekli süre

$$EPDF = \frac{C_s}{PC_h} \qquad 3.12$$

$$TRC(T) = \text{C} + \text{T.dönem sonuna kadar elde tutma maliyeti} \qquad 3.13$$

$$TRC(T) = C + Ph\sum(k-1)R_k \qquad 3.14$$

5. Silver-Meal Yöntemi (SM-Silver Meal)

Bu modelin kullanılmasındaki amaç, zaman değişkenliğinden dolayı oluşan karmaşayı çözecek şekilde, oldukça basit bir yaklaşım ile sonuca ulaşmaktır. Bu model ile iki şekilde çözüme gidilebilir. Çözüm yöntemleri ilki dönem başında sipariş ve ikincisi ise dönem ortasında sipariş verilmesidir.

$TRC(T)$: T dönemleri boyunca toplam ilgili maliyet

T : Tedarikin kapsayacağı dönem sayısı

TC : Toplam maliyet

$TRC(1)$: İlk aydaki toplam maliyet

D :Talep miktarı

D_i : i. Dönemdeki talep miktarı

v : Birim maliyet

r : Birim stoklama maliyet oranı(%)

Q : Optimum Sipariş Miktarı

$$TRC(T) = \frac{TRC(1) + D(T-1)vr + 2D(T)v}{T} \qquad 3.15$$

$TC(T+1) > TC(T)$ olduğu zaman T değeri alım yapılacak dönem sayısını verir $Q = \sum_{1}^{T} D_i$ denkleminden optimum sipariş miktarı Q hesaplanır [30]. Silver Meal yöntemi Axsater S. tarafından 3.14 ve 3.15 de özet olarak ifade edilmiştir.

Ch :elde bulundurma maliyeti

A :hazırlık maliyeti

k :alım yapılacak dönem

$$\frac{A + \mathrm{Ch}\sum_{j=2}^{k}(j-1)d_j}{k} \le \frac{A + \mathrm{Ch}\sum_{j=2}^{k-1}(j-1)d_j}{k} \qquad 2 \le k \le n \qquad 3.16$$

$$\frac{A+\mathrm{Ch}\sum_{j=2}^{n+1}(j-1)d_j}{n+1} > \frac{A+\mathrm{Ch}\sum_{j=2}^{n}(j-1)d_j}{n} \qquad 3.17$$

6. Wagner-Whitin Yöntemi (WW- Wagner-Whitin)

Wagner-Whitin belirli bir zaman aralığındaki deterministik ve dinamik parti büyüklüğü belirleme probleminde optimum çözümü sunar. Tüm dönemlerin taleplerinin karşılanması gerekir. Planlanan zaman aralığındaki dönemler sabit ve belirli bir uzunlukta olduğu kabul edilmiştir. Siparişler taleplerin dönem başında karşılanacağını garanti etmelidir. Bu algoritma minimum maliyet politikasını elde etmeye yarayan dinamik bir programlama yaklaşımıdır. Literatürde kapasite kısıtlı ve kapasite kısıtsız olarak tasniflendirilmiş edilmiş olup matematik modeli aşağıdaki gibidir [31].

D_k : i. dönem talebi

Q_k : i. dönem sipariş miktarı

P_k : k. dönemlerdeki en az maliyet

A : Sabit sipariş maliyeti

R_t : t dönem deki stok miktarı

c : Birim başına değişken sipariş verme maliyeti.

C_{jk} : j ve k dönemleri arasındaki toplam maliyet.

h : Birim zamanda elde bulundurma maliyeti

Dönemdeki verilecek olan sipariş miktarı formül 3.16'de,

$$Q_{j+1} = D_{j+1} + D_{j+2} + \ldots\ldots\ldots + D_k \qquad 3.18$$

Dönemler arasındaki maliyet formül 3.17.'de,

$$C_{jk} = A_{j+1} + c_{j+1} + \sum_{t=j+1}^{k-1} h_t R_t \qquad 3.19$$

Dönem sonlarında kalan stok miktarının formül 3.18.'de ifade edildiği gibidir.

$$R_t = Q_{j+1} - \sum_{r-j-1}^{t} D_r = \sum_{r-t+1}^{k} D_r \qquad j < t < k \qquad 3.20$$

Formül 3.17. bu aşamadan sonra tekrar düzenlendiğinde 3.19 ve 3.20'deki gibi olacaktır.

$$C_{jk} = A_{j+1} + c_{j+1}Q_{j+1} + \sum_{t=J+1}^{k-1} h_t \sum_{r-t+1}^{k} D_r \qquad 3.21$$

Yukarıda belirtilen denkleme göre, $j+1$periyodu, (k)periyotlu bir sürede başlangıç ve bitiş stoklarının sıfır olması ve stokların boşalmasına izin verilmemesi koşulları ile son alımın yapılacağı bir periyot olacaktır.

Bu yöntem $P_1 + P_2 + \ldots\ldots\ldots + P_n$ değerlerinin bulunmasına dayanmaktadır, (P_n) bulunduğunda (n) periyotlu zaman dönemi için minimum maliyet bulunmuş olacak ve (jn) kullanılarak, geriye doğru gidilerek ekonomik sipariş miktarı bulunacaktır.

B. Yapay Sinir Ağları

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beynin bulunduğu 3 katmanlı bir sistem olarak açıklanır. Alıcı sinirler organizma içerisinden ya da dış ortamlardan algıladıkları uyarıları, beyine bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri (effector) ise, beyinin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür. İnsan beyni; öğrenme, birleştirme, uyarlama ve genelleştirme yeteneği nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilir. Şekil 2.1 de Biyolojik sinir hücresi ve bileşenleri gösterilmektedir [16]. İnsanlığın doğayı araştırma ve taklit etme çabalarının en son ürünlerinden bir tanesi, yapay sinir ağları (YSA) teknolojisidir.

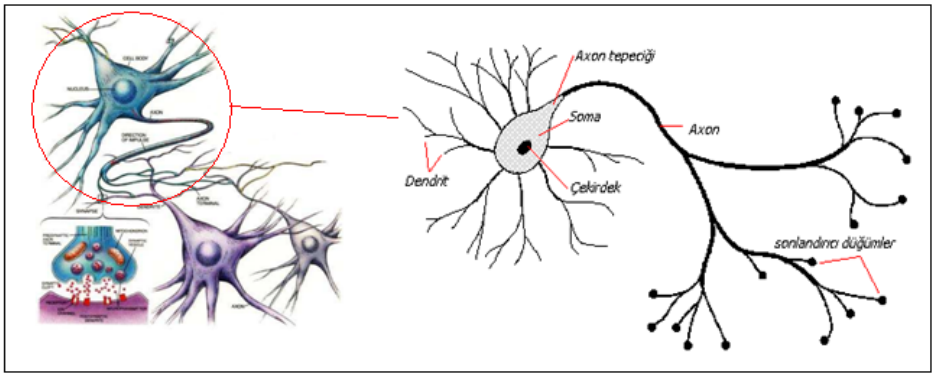

Şekil 2.1. Basit bir sinir hücresi [16]

Yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmalarından oluşan ağ yapısı genellikle katmanlar şeklinde düzenlenir. İnsan beyninin bilgi işleme yöntemine uygun olarak YSA'lar, bir öğrenme sürecinden sonra bilgiyi toplama, hücreler arasındaki bağlantı şekilleri ve ağırlıkları ile bu bilgiyi saklama ve genelleme yapabilme yeteneğine sahip paralel dağılmış işlemcilerden oluşur.

1. Neden Yapay Sinir Ağları

İnsanlığın gelişimi insan beynine pek çok arzu edilen özellikler bahşetmiştir. Bu özellikler şunlardır:

1. Masif paralellik,
2. Dağınık gösterim ve hesaplama,
3. Öğrenme yeteneği,
4. Genelleme yeteneği,
5. Çok yönlülük veya adaptasyon
6. Doğal içeriksel bilgi işleme
7. Hata toleransı
8. Düşük enerji tüketimi

Biyolojik sinir hücrelerini temel alan aygıtların arzu edilen bu özelliklere sahip olması beklenmektedir. Günümüz dijital bilgisayarları sayısal hesaplama ve ilişkili sembolleri işleme alanında insan oğlundan daha iyi performans göstermektedir. Aslında insanoğlu anlamaya dayalı karamaşık problemleri çaba harcamadan dünyanın en hızlı bilgasayarı gibi çözebilmektedir.

1. Örüntü tanıma
2. Gruplama ve Kategorize etme
3. Fonksiyon yaklaştırma
4. Tahmin
5. Optimizasyon

Yapay sinir ağları birbirlerine bağlı büyük sayıdaki işlemcilerden meydana gelen massif (yekpare) parallel sistemlerdir. Yapay sinir ağları insanda olduğu bilinen bazı örgütsel"

presipleri "kullanmaya çalışmaktadır. Bilgisiyar mühensileri ve bilim adamlarının ilgisini çeken bu aşamadan sonraki problemlera aşağıda verilmiş olup, şekilsel gösterimi Şekil 2.2,3,4,5,6'da verilmiştir [32].

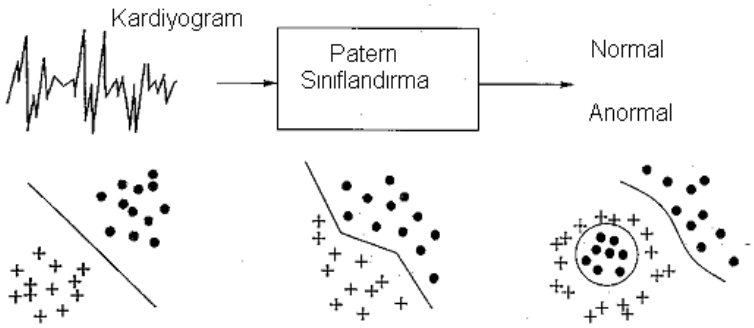

Şekil 2.2. Örüntü tanıma [32].

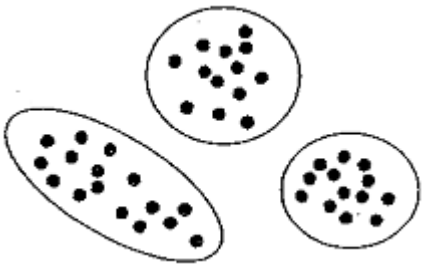

Şekil 2.3. Gruplama [32].

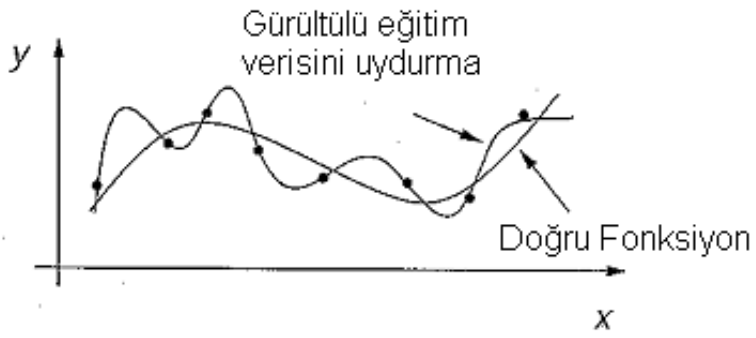

Şekil 2.4. Fonksiyon yaklaştırma [32].

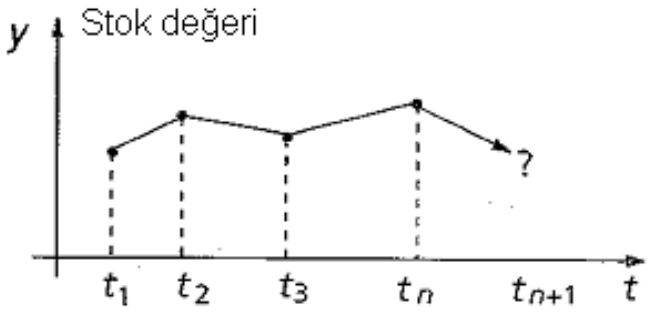

Şekil 2.5 Tahmin [32].

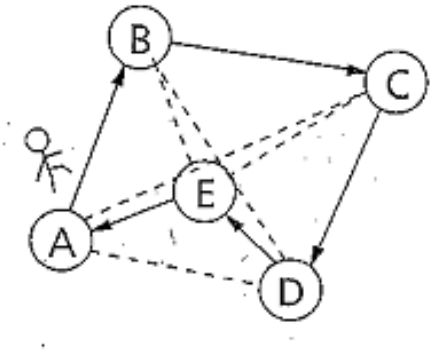

Şekil 2.6. Optimizasyon [32].

2. Yapay Sinir Ağı Hücresi

Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. En temel nöronun matematiksel modeli ve katman yapısı Şekil 2.7' de görülmektedir[33], [34]. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler yani girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar, net giriş, girişlerle bu girişlerle ilgili ağırlıkların çarpımının bir

sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışını hesaplar ve bu işlem aynı zamanda nöron çıkışını verir.

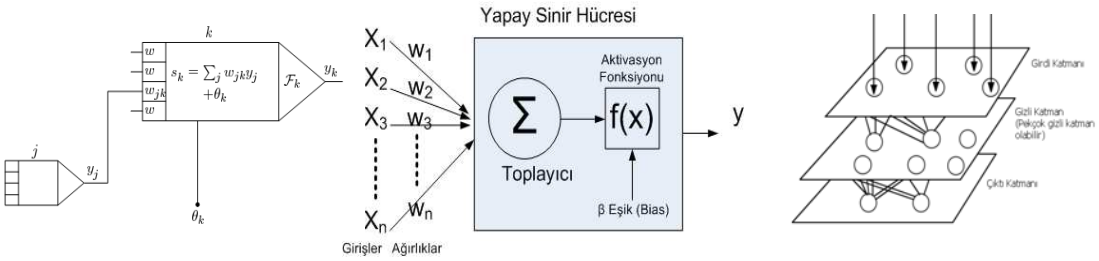

Şekil 2.7. Yapay sinir ağı matematiksel modeli ve katman yapısı [33],[34].

Çıkış, $o = \boldsymbol{f}\,(W.X + b)$ şeklinde nöron çıkışı hesaplanır. Buradaki W ağırlıklar matrisi, X ise girişler matri b ise hesaba katılmayan sabit ve diğer ifadeleri temsil etmektedir.

" n" giriş sayısı olmak üzere; ağırlıklar formül 3.20 de girdiler ise 3.21 deki gibi ifade edilebilir.

$W = w_1, w_2, w_3, ..., w_n$ 3.22

$X = x_1, x_2, x_3, ..., x_n$ 3.23

Şeklinde yazılabilir. Ağın fonksiyonu 3.22 de olduğu gibi ifade edilebilir.

$net =$ ve $o = f\,(net)$ 3.24

Buradan hareketle

$$o = f\left(\sum_{i=1}^{n} w_i x_i + b\right)$$ 3.25

şeklinde de yazılabilir. Yukarıdaki formülde görülen **f** aktivasyon fonksiyonudur.

3. Aktivasyon Fonksiyonları

Matematiksel olarak modellenmiş bir yapay sinir hücresinin çıktısının büyüklüğünü sınırlandıran fonksiyondur [35]. Sıkıştırma, transfer, işlemci veya eşik fonksiyonu olarak da isimlendirilebilir. Bir ağdaki tüm hücrelerin aktivasyon fonksiyonu birbirinden farklı olabilir. En çok kullanılan aktivasyon fonksiyonları aşağıda gösterilmiştir [36]. Aktivasyon fonksiyonları gösterim ve formülleri Şekil 2.8 , 3.9, 3.10, 3.11, 3.12, 3.13'de ifade edildiği gibidir. bilgiler ve formülasyonları aşağıda arz edildiği gibidir.

a. Lineer Fonksiyon

Hücreye gelen veriler bir katsayısı ile çarpılarak sonuç üretilir. =1 ise girdiler olduğu gibi çıkar. Formül 3.24 ile ifade edilebilir.

$$f(net) = net \qquad 3.26$$

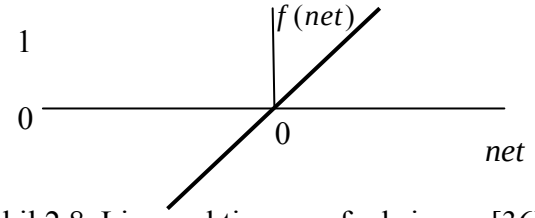

Şekil 2.8. Lineer aktivasyon fonksiyonu [36].

b. Step Fonksiyonu

Gelen veri belirlenen bir eşik değerinin üstünde ya da altında olmasına göre 1 ya da 0 değerlerini alır. f(net) formül 3.25 ile ifade edilir.

$$f(net) = \begin{cases} 0 & net \le 0 \\ 1 & net \ge 0 \end{cases} \qquad 3.27$$

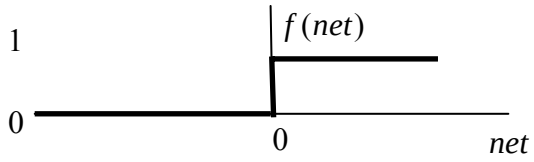

Şekil 2.9. Step aktivasyon fonksiyonu [36].

c. Eşik Değer Fonksiyonu

Gelen verilerin belirlenen değerler arasında veya değerden büyük ya da küçük olmasına göre değer alırlar. Belirlenen değerler arasında ise gelen değerin kendisi çıktı olur.

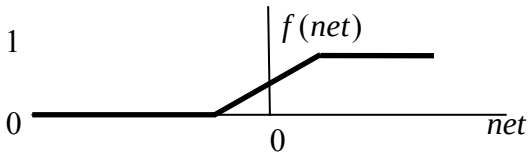

Şekil 2.10. Eşik değer aktivasyon fonksiyonu [36].

ç. Hiperbolik Tanjant Fonksiyonu

Çıktı değeri hücreye gelen verilerin tanjant fonksiyonuna tabi tutulmasıyla hesaplanır [16]. Formül 3.26 ile ifade edilir.

$$f(net) = \frac{e^{net} - e^{-net}}{e^{net} + e^{-net}} \qquad 3.28$$

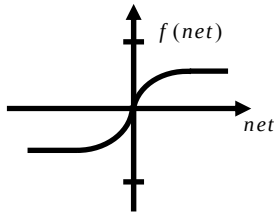

Şekil 2.11. Hiperbolik tanjant aktivasyon fonksiyonu [36].

d. Sigmoid Fonksiyonu

Yapay sinir ağları oluşturulurken en çok kullanılan aktivasyon fonksiyonudur. Doğrusal ve doğrusal olmayan davranışlar arasında denge sağlayan sürekli artan bir fonksiyon olarak tanımlanır [37].

$$f(net) = \frac{1}{1 + e^{-net}} \qquad 3.29$$

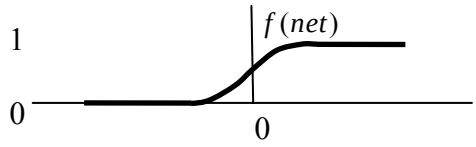

Şekil 2.12. Sigmoid aktivasyon fonksiyonu [36].

e. Gauss Fonksiyonu

$$f(net) = \exp(\frac{net^2}{\sigma^2}) \qquad 3.30$$

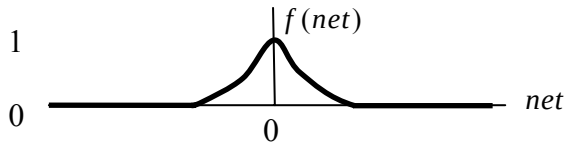

Şekil 2.13. Gauss aktivasyon fonksiyonu [36].

4. Yapay Sinir Ağı Modelleri

En basit ve en genel yapay sinir ağları tek yönlü sinyal akışını kullanırlar. Yapay sinir ağı modelleri temel olarak iki grupta toplanmaktadır. İleri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları. Ağ mimarisine göre yapay sinir ağlarının sınıflandırması Şekil 2.14 de verilmiştir [3].

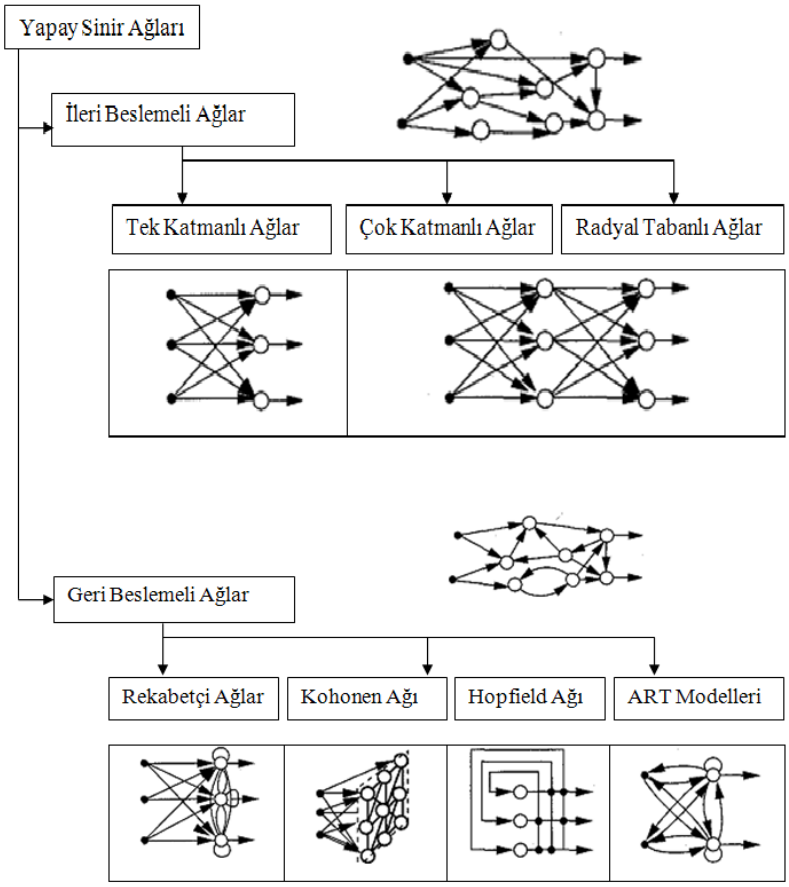

Şekil 2.14. Ağ mimarisine göre yapay sinir ağlarının sınıflandırılması [3]

5. Yapay Sinir Ağlarının Eğitilmesi

Yapay sinir ağlarının öğrenme sürecinde de, tıpkı dış ortamdan gözle veya vücudun diğer organlarıyla uyarıların alınması gibi dış ortamdan girişler alınır, bu girişlerin beyin merkezine iletilerek burada değerlendirilip tepki verilmesi gibi yapay sinir ağında da aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı üretilir. İnsan beynin çalışma prensibinde olduğu gibi yapay sinir ağlarının öğrenmesinde iki paradigma mevcuttur. Birincisi açık bir şekilde ağ ağırlıkları ayarlanır. Bir nevi deneme yanılma metodudur.

(öğretmensiz öğrenme). İkinci metot ise tecrübeyle veya geçmiş kayıtlardan elde edilen verilerin ağ çıktısı ile karşılaştırılması sağlanarak hata azaltılıp gerçek çıkışa yaklaşılmaya çalışılır (öğretmenli öğrenme) [33].

6. Yapay Sinir Ağı Modelleri

Bu bölümde yapay sinir ağlarının literatürde yer alan sınıflandırmasına göre genel bilgi verilecektir.

a. Tek Katmanlı Ağ (TKA)

Yapay sinir ağları ile ilgili çalışmaları tek katmanlı algılayıcılar ile başlamıştır. Bu algılayıcıların en önemli özelliği problem uzayını bir doğru veya bir düzlem ile sınıflara ayırmalarıdır. Problemin girdileri ağırlıklar ile çarpılıp toplandıktan sonra elde edilen değerin bir eşik değerinden büyük veya küçük olmasına göre girdinin sınıfı belirlenir[38].

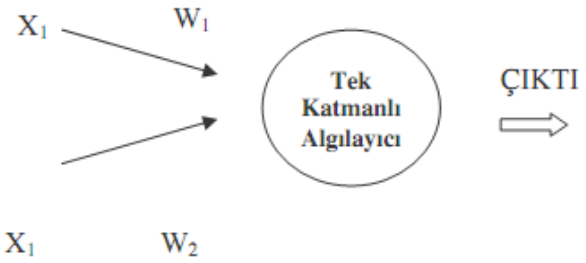

Şekil 2.15. Tek katmanlı yapay sinir ağı [38].

b. Çok Katmanlı Yapay Sinir Ağı (ÇKA)

Çok katmanlı yapay sinir ağları (ÇKA) en çok kullanılan ağ yapılarından birisidir. Bu ağda bilginin akışı ileri yönlüdür. Bu modelde, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Her bir katmanda en az bir nöron bulunur. ÇKA (Multi Layered Perceptron)' daki herhangi bir nöron çıkışı

$$a_j = f(\sum_i w_{ji} z_i) \qquad 3.31$$

ile hesaplanır.

Bir katmandaki bütün işlem elemanları bir önceki katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Bunun için ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı tamamen uygulanan problemlerin giriş sayısına bağlıdır. Ara katman sayısı ve ara katmandaki işlem elemanı sayısı ise deneme yanılma yoluyla bulunur. Çıkış katmanındaki eleman sayısı ise yine uygulanan probleme dayanılarak belirlenir.

Bu ağ modeli özellikle mühendislik problemlerinin çözümlerinde ve uygulamalarda en çok kullanılan sinir ağı modeli olmuştur. Birçok öğretme algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir. ÇKA ağlarında, ağa bir örnek uygulanır ve örnek neticesinde nasıl bir sonuç üretmesi gerektiği bildirilir [39].

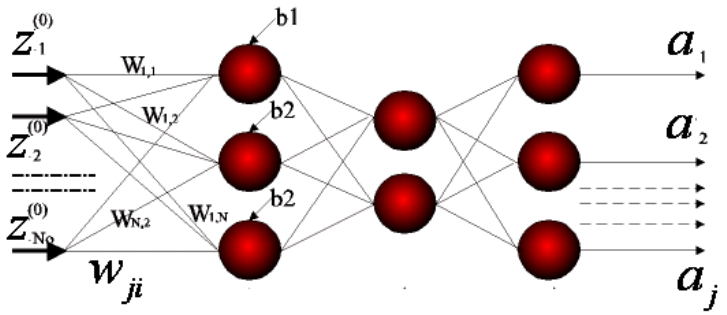

Şekil 2.16. Çok katmanlı yapay sinir ağı topolojisi [39]

c. İleri beslemeli Modüler Yapay Sinir Ağları (Feed Forward Perceptron- FFP)

Bu model çok katmanlı yapay sinir ağlarının genişletilmiş sürümüdür. Bu ağın teorisi ve öğrenme kuralı çok katmanlı yapay sinir ağı ile aynıdır. Katmanlar modüllerin içine parçalandırılmıştır (segment). Ağ topolojisinin içinde her bir alt katmanda fonksiyonların uzmanlaşmasına katkı sağlayan bazı yapılar oluşturmaya eğilimlidir.

Sadece aynı sayıdaki işlemciye sahip çok katmanlı yapay sinir ağına nazaran daha az ağırlığa ihtiyaç duyması dikkat çekicidir. Bu durum ihtiyaç duyulan eğitim örnek sayısını artırır. Bu ağlar çok katmanlı ağlardan daha hızlı eğitilebilirler. Bu tip ağlar gizli katman ve çıktı katmanları için ağırlık adaptasyonlarına yardıma ve çıktı ile kısa yol bağlantısına sahiptir.

İleri beslemeli modüler yapay sinir ağları çok katmanlı yapay sinir ağlarının aksine katmanlar birbirine tam olarak bağlı değildir. Böylece aynı sayıda proses elemanına sahip çok katmanlı yapay sinir ağına nazaran daha az sayıda ağırlığa ihtiyaç duymaktadır. Eğitim hızı artarken aynı doğruluk derecesi için daha fazla eğitim örneğine ihtiyaç duyar.

Bu tip ağların dezavantajı ise çok katmanlı ağın içinde segment oluşturmanın pek çok yolu vardır. Veri tabanlı modüler topolojilerden hangisinin en iyi tasarım olacağı açık değildir. Her modülün eğitildiği veri dilimi üzerinde uzmanlaşacağının garantisi yoktur. Bu ağ yapısına çok katmanlı yapay sinir ağı ve ileri beslemeli yapay sinir ağı topolojileri alternatiftir [40].

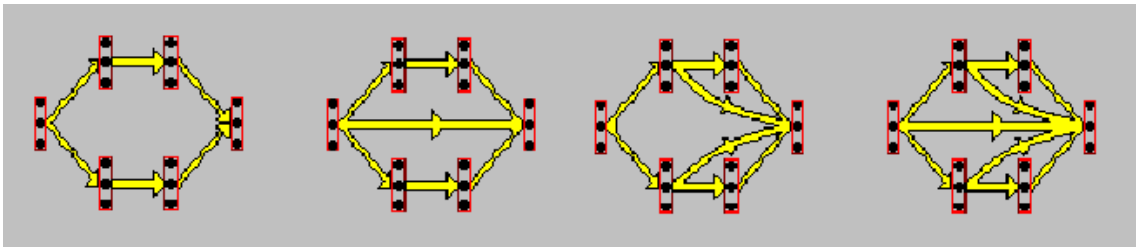

Şekil 2.17. İleri beslemeli modüler yapay sinir ağı topolojisi [37]

ç. Radyal Tabanlı Yapay Sinir Ağları (Radial Basis Function Networks-RBF)

Radyal tabanlı yapay sinir ağları, duyarlı almaç bölgelerinin olduğu giriş tabakası, radyal tabanlı nöronları içeren gizli tabaka ve çoğunlukla doğrusal aktivasyon fonksiyonlu nöronlardan ibaret çıkış tabakasından oluşur. Radyal tabanlı ağlar, geri yayılım algoritmalı ileri beslemeli ağlardan daha fazla nöron kullanımına ihtiyaç

duysada eğitim süresi çok daha kısadır. Yoğun eğitim verisiyle daha iyi sonuçlar verir [16].

Radyal tabanlı ağlar haritalama problemlerini ÇKA'larden farklı bir şekilde çözer. Gauss transfer fonksiyonunu destekleyen gizli katmanlardan özel bir tanesi girdi bilgilerin girdi verilerinde boşluklara dikkatli bir şekilde yerleştirilir. Daha sonra Gauss fonksiyonun çıktısı arzu edilen çıktıları üretmek üzere liner olarak ağırlıklandırılır. İlave olarak radyal tabanlı fonksiyonların her birinin pozisyonlarının belirlenir, rekabetçi öğrenme gibi öğretmensiz öğrenme tekniği kullanılır. Girdi aralığı veri dizilerinin içine aralıklandırılır ve her birinin ölçüsü girdi verilerinin yapısından elde edilir. Çıktıların ağırlıkları öğretmenli öğrenme kullanılarak elde edilir. Çıktı birimlerinin liner olmasından dolayı yakınsama genellikle daha hızlıdır. Gauss sinirleri başlangıçta çatlamış bileşenler gibi görülür. Bu işlemlerden sonra desteksiz öğrenme katmanın eğitimi sonlandırılır, ağırlıkları sabitlenir ve öğretmenli (destekli) yapı eğitime başlar. Bu yaklaşım eğitim süresini geliştirmeye yöneliktir [37].

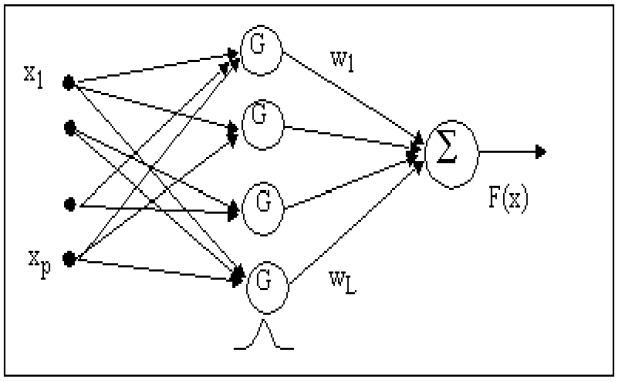

Şekil 2.18. Radyal tabanlı ağ topolojisi [37].

$$y = \frac{\sum_{n=1}^{N} d(n) Exp\left[-\frac{\left[x_0 - x(n)\right]^2}{2\sigma^2} \right]}{\sum_{n=1}^{N} Exp\left[-\frac{\left[x_0 - x(n)\right]^2}{2\sigma^2} \right]} \qquad 3.32$$

d. Kohonen Ağı (Self Organizing Feature Map-SOFM)

Kohonen ağı ilk defa T. Kohonen tarafından geliştirilmiştir. Kendini örgütleyen ağ mimarisi olarak geleneksel sinir ağı mimarilerine kalıcı bir alternatif olarak keşfedilmiştir. Sadece sinir ağının nasıl olduğunu sormak mümkündür. Kendini örgütleyen ağlar 1981 'de keşfedilmiştir. Uygulamaları mühendislik uygulamalarında idi. Daha sonra algoritma, danışmansız öğrenmeyi, kümelemeyi, görselleştirmeyi, veri organizasyonu, sınıflandırma ve araştırmada kullanabilen geniş bir uygulama alanında standart bir veri analizi metodu olarak kabul edilmiştir [41].

Danışmanlı öğrenme, doküman sınıflandırmada giriş verilerinin çok olması ve her bir düğümün bir vektör olarak gösterilmesi nedeniyle uygun görülmemektedir. Bunun yerine danışmansız öğrenme yaklaşımı tercih edilmektedir. Kendini örgütleyen haritaların en önemli avantajı ağın kendi kendini eğitmesidir. Bu ağların eğitiminde dışarıdan bir danışman müdahalesine gerek duyulmamaktadır. Ağ tamamen otomatik olarak eğitilmektedir. Yani tek yapmamız gereken ağa giriş verilerini vermek ve ağın kendi kendini eğitmesini sağlamaktır [41].

Kendini örgütleyen haritalar, bir dikdörtgen biçiminde 2 boyutlu düğümlerden oluşan bir ızgara ile gösterilir. Örneğin bir harita 10 sütun ve 12 satırdan oluşuyorsa, bu haritada 120 adet düğüm bulunur. Her bir düğüm bir ağırlık vektörü ile ilişkilendirilmiştir. Bu vektörler veri fihristinde bulunan terimlere karşılık gelir. Her bir vektör elemanının 0 ile 1 arasında olan ilk değeri genellikle rastgele atanır [41].

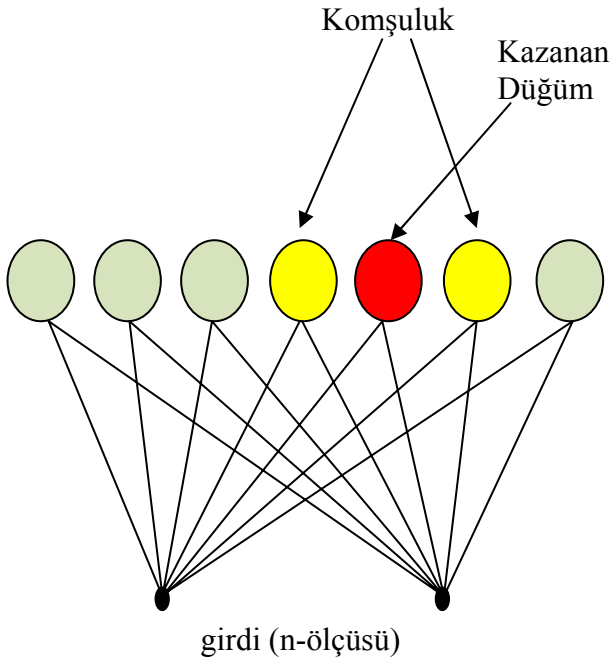

Şekil 2.19. Kohonen mimarisi [41].

Kohonen ağlarında kullanılan öğrenme algoritması bu ağlara ismini de veren, SOM (Self Organizing Maps) algoritmasıdır. Bu ağlarda kullanılan öğrenme algoritması denetimsizdir. Yani, ağ eğitilirken bağımlı değişken kullanılmaz. Veri setindeki giriş vektörleri ağa girildikçe, ağ kendi kendini düzenler ve referans vektörleri oluşur.

C. Analitik Hiyerarşi Prosesi (AHP)

1977 yılında Thomas L. Saaty tarafından geliştirilen çok ölçütlü karar verme tekniğidir. Karar alınırken grup veya bireyin önceliklerini de dikkate alan, nitel ve nicel değişkenleri bir arada değerlendiren matematiksel bir yöntemdir.

AHP ile karar vericilerin farklı psikolojik ve sosyolojik durumlardaki gözlemleri de dikkate alınarak kendi karar verme mekanizmalarını tanıma olanağı sağlanmaya çalışılmaktadır. Bu yöntemle karar vericilerin daha etkin karar vermeleri amaçlanmıştır [21].

AHP'de öncelikle amaç belirlenir ve bu amaç doğrultusunda amacı etkileyen faktörler saptanmaya çalışılır, bu aşamada karar sürecini etkileyen tüm faktörlerin

belirlenebilmesi için anket çalışmasına veya bu konuda uzman kişilerin görüşlerine başvurulur [42].

Amaç, faktör ve alt faktörler belirlendikten sonra, faktör ve alt faktörlerin kendi aralarındaki önem derecelerinin belirlenmesi için ikili karşılaştırma karar matrisleri oluşturulur. Bu matrislerin oluşturulmasında 1-9 önem skalası kullanılır. Yapılan çalışma sonunda verilecek karar birçok kişiyi etkileyecek yapıda ise ikili karşılaştırma karar matrisleri farklı kişilerin yargılarının birleştirilmesi ile oluşturur. Bu birleştirme işleminde birçok araştırmacı, tutarlı ikili karşılaştırma matrisleri elde edebilmek için, geometrik ortalama yönteminin kullanılır [43],[44]. Saaty tarafından önerilen 1-9 önem skalası en iyi sonuçların elde edilmesini sağlamaktadır. Bunun dışındaki 1-5, 1-7, 1-15 ve 1-20 gibi önem skalaları uygun çözümü elde etmede yetersiz kalmaktadır [21].

1. AHP'nin Uygulama Aşamaları

Karar verme problemlerinin AHP ile çözümünde dört adım bulunmaktadır [45]. Geçekleştirilen işlem adımları aşağıda özetlenmiştir. [46]

1. Adım: Problemin hiyerarşik bir düzende alt problemlere ayrıştırılması

2. Adım: Karşılaştırmalı yargılar veya ikili karşılaştırmalar: ikili karşılaştırma (göreli önem dereceleri) (pairwise comparison) terimi, iki kriterin birbirleriyle karşılaştırılması anlamına gelir ve karar vericinin yargısına dayanmaktadır. Saaty'nin [47] geliştirmiş olduğu 1-9 puanlı tercih ölçeğinden faydalanılarak, hiyerarşide yer alan bileşenlerin göreli önemlerine ilişkin, karar vericinin kişisel yargılarını yansıtan ikili karşılaştırmalar; n, değerlendirilecek kriter sayısı ve; i özelliğinin, j özelliğine göre önemini göstermek üzere, A matrisi elde edilmektedir.

$$A = (a_{ij})_{nxn} = \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nn} \end{pmatrix} \qquad 3.33$$

$a_{ii} > 0$ olmak üzere, matris elemanları arasında; $a_{ij} = \frac{1}{a_{ij}}$ ve $a_{ii} = 1$ ilişkisi bulunmaktadır. Karşılaştırmalarda; i. özelliğinin ağırlığı w_i, j özelliğinin ağırlığı Wj ile gösterilmek üzere; $a_{ij=} \frac{w_i}{w_j}$ ile ifade edilebilir. Bu durumda A matrisi;

$$A = \begin{pmatrix} w_1/w_1 & w_1/w_2 & . & w_1/w_n \\ w_2/w_1 & w_2/w_2 & . & w_2/w_n \\ . & . & . & . \\ w_n/w_1 & w_n/w_2 & . & w_n/w_n \end{pmatrix} = \begin{pmatrix} 1 & a_{12} & . & a_{1n} \\ 1/a_{12} & 1 & . & a_{2n} \\ . & . & . & . \\ 1/a_{n1} & 1/a_{n2} & . & 1 \end{pmatrix} \quad 3.34$$

3. Adım: AHP'nin üçüncü adımı "sentezleme" dir. Bu adımda, her kriter için öncelik vektörleri bulunur. Karşılaştırmaların tam tutarlı olduğu durumlarda; $a_{ik} = a_{ij}a_{ik}$. Ancak, gerçekte her zaman böyle bir ideal durum söz konusu olmadığından, bu eşitlik de sağlanamamaktadır. Bu durumda, wi 'yi aşağıda gösterilen eşitlik ile elde etmek daha uygun olacaktır [21].

$$w_i = \frac{1}{n}\sum_{j=1}^{n} a_{ij}w_j \quad 3.35$$

Yukarıdaki eşitlik;

$$Aw = nw \quad 3.36$$

ile gösterilebilir.

Burada; n, A matrisinin bir özdeğeri ve w'de bu özdeğerlere ait özvektördür. Karar vericinin tam tutarlı olduğu durumda, A'nm rankı "1" dir ve bu nedenle biri hariç tüm özdeğerleri "0"dır. Bu durumda, A'nın izi "n" e eşittir. λ_i, A'nın özdeğerlerini göstermek üzere;

$$\sum_{i=1}^{n} \lambda_i = iz(A) = n \quad 3.37$$

dir [48]. Tutarlılık durumunda, A'nın en büyük özdeğeri “n” dir (λ_{mak}). İdeal tutarlık söz konusu olmadığı durumda, λ_{mak}, n'ye eşit olmayacaktır $(\lambda_{mak} > n)$. Eğer, tutarsızlık belirli sınırlar dâhilinde tutulursa, λ_{mak}'ın, n'ye yakın olması sağlanmaktadır. Bu durumda w_i aşağıdaki şekilde de yazılabilir.

$$w_i = \frac{1}{\lambda_{mak}} \sum_{j=1}^{n} a_{ij} w_j \text{ yada } Aw = \lambda_{mak} w \qquad 3.38$$

olur.

4. Adım: Tutarlılıkların hesaplanarak, kararın alınmasıdır. Ağırlık vektörünün elde edilmesi için, çeşitli yöntemler olmasına rağmen en sık kullanılan yöntem; Özvektör Yöntemi ' dir [49]. EVM vektörünün kullanıldığı durumda, AHP'deki uyum oranı;

$$CR = \frac{CI}{RI} \qquad 3.39$$

ile hesaplanmaktadır [51]. Burada $CI; \lambda_{mak}$ 'ın, n'den ne kadar saptığını gösteren ve

$$CI = \frac{(\lambda_{mak} - n)}{(n-1)} \qquad 3.40$$

şeklinde hesaplanan tutarlılık oranı, RI ise; rassal olarak oluşturulmuş ikili karşılaştırma matrisinin tutarlılık indeksidir [50].

Hesaplanan CR değerinin 0,10 dan küçük olması; "karar vericinin yaptığı karşılaştırmaların tutarlı" olduğunu göstermektedir. CR değerinin 0,10' dan büyük olması ya AHP' deki bir "hesaplama hatasını" ya da "karar vericinin karşılaştırmalarındaki tutarsızlığı" göstermektedir [50].

III. Uygulama

A. Verilerin Toplanması ve Düzenlenmesi

Çalışmanın bu aşamasında yapay sinir ağlarının eğitiminde kullanılacak veriler toplanmıştır. Bu amaç uygulamanın yapıldığı X işletmesinin malzeme ihtiyaç planlama (MİP)sisteminden son beş yıla ait veriler sistem içerisinde işletmeye özgü özel sorgulama programı vasıtası ile elektronik ortamda alınmıştır. Elde bulundurma maliyeti, sipariş maliyeti ve değişken maliyetler işletmeye özgü malzeme ihtiyaç planlama sisteminden elektronik ortamda alınmıştır. Elektronik ortamda alınan veriler 186 farklı malzemeye ilişkin son 5 yıla ait 12 dönem halindeki talep verileridir.

Veriler düzenlendikten yapay sinir ağı eğitiminde, testinde ve eğitimi tamamlanan yapay sinir ağı modellerinin karşılaştırılmasına yönelik kullanılacak, veri işlemlerinde hangi malzemelere ait verilerin kullanılacağının belirlenmesine ihtiyaç duyulmuştur. Bu amaçla da analitik hiyerarşi prosesi kullanılmıştır. AHP kullanılarak Ek-1'de listesi verilen 186 kalem malzemeden işletme için en önemli malzemer belirlenmiştir. AHP 186x186 bir matrisin işlemlerinin uzun süreceği ve anketörler tarafından tam anlamlı değerlendirme yapılamama ihtimali nedeniyle veriler gruplandırılmıştır.

B. Verilerin Gruplandırılması

İncelenen veriler kullanım yerlerine ve malzemenin cinsine göre gruplandırılmıştır. Gruplandırmada malzemenin tedarik kaynağı değerlendirmeye alınmıştır. Yapılan malzeme gruplandırması aşağıda sunulmuştur.

Yüksek Basınç Elemanları: Üretim faaliyetlerinde kullanılan genellikle hava araçlarına yönelik malzemelerdir.
Tamirlik Malzemeler: Bakım onarım faaliyetleri kapsamında onarımı yapılan sistem üzerinde faal olamayan malzemelerdir.
Kit ve Takım Malzemeler: Üretim faaliyetlerinde kullanılan gerek fabrika bünyesinde imal edilen, gerekse dış kaynaktan tedarik edilen kit malzemeler.
Yedek Parça Grubu: Üretim faaliyetleri içerisinde imal edilen yedek parçalar.

Hammadde ve Sarf Malzemeler: Sadece dış kaynakta tedarik edilen malzemeler.

Kontrol Üniteleri: Üretilen komplike mamuller üzerindeki mekanik ve elektronik otomatik kontrol ünitelerdir.



Şekil 2.20. Yüksek basınç elemanları grubuna ilişkin malzeme resimleri



Şekil 2.21. Tamirlik malzemeler grubuna ilişkin malzeme resimleri

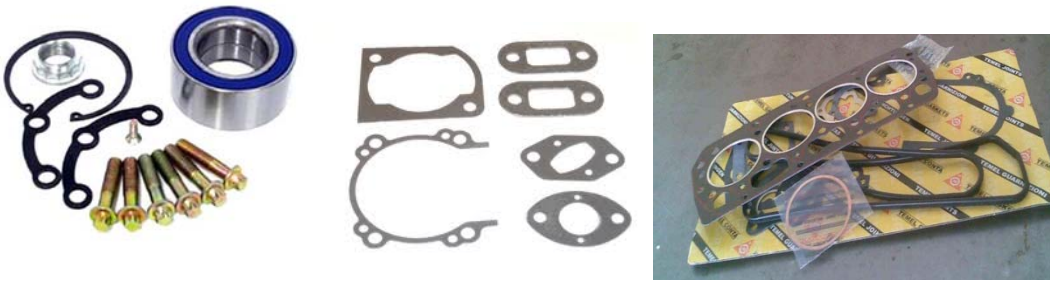

Şekil 2.22. Kit ve takım malzemeler grubuna ilişkin malzeme resimleri



Şekil 2.23. Yedek parça grubuna ilişkin malzeme resimleri



Şekil 2.24 Hammadde ve sarf malzemeler grubuna ilişkin malzeme resimleri



Şekil 2.25. Kontrol ünitelerine ilişkin malzeme resimleri

C. Eğitim Ve Testlerde Kullanılacak Verilerin Seçimi

Yapay sinir ağlarının eğitim, test ve veri üretimi amacı ile kullanılacak malzeme gruplarının seçilmesi amacı ile AHP kullanılmıştır. İşletme için önemli olan malzeme grubun bulunması amaçlanmıştır. Buradan hareketle yapılacak deneylerin ve yapılması teklif edilebilecek iyileştirmelerin işletmenin ana faaliyet alanındaki malzemeler yönelik olması sağlanacaktır. Bu amaçla fabrika bünyesinde görevli müdür, atölye şefi, malzeme tedarikçisi gibi kademelerde görev yapan alanından uzman 9 faklı personele

anket uygulanmıştır. Anket kapsamında personelin yukarıda verilen malzeme gruplarının aşağıda verilen kriterlere göre derecelendirilmesi istenmiştir. Görevli personel malzeme gruplarının içeriğindeki malzemeler hakkında AHP süreci hakkında bilgilendirilmiştir. Anketin uygulanması amacı ile Excel tablosu hazırlanarak uzman personele dağıtılmıştır. Şekil 2.33 'da uzman personele gönderilen anket formunun boş hali sunulmuştur.

Kriter-1: Üretim etkinliği (doğrudan etkisi olan/dolaylı etkisi olan)
Kriter-2:Çalışma emniyeti ve güveni: (kullanım yeri/sertifikasyon gereksinimleri)
Kriter-3: Teknolojik özellik (altyapı yeterliliği/özel işlem gerektiren prosess durumu)
Kriter-4: Katma değer/maliyet etkinlik (maliyet-fiyat durumu/teknik doküman maliyet)
Kriter-5:İhtiyaç kullanım durumu (yıllık kullanım miktarı/çevrim yedeği sağlanabilirliği/arıza sıklık durumu)
Kriter-6: Tedarik durumu/yeterliliği (tedarik sürdürülebilirliği/tedarik süresi /tedarik altarnatifi /ithalat bağımlılığı)
Kriter-7: Mevcut iş gücü/ihtisas durumu (iş gücü durumu/kritik ihtisas durumu)

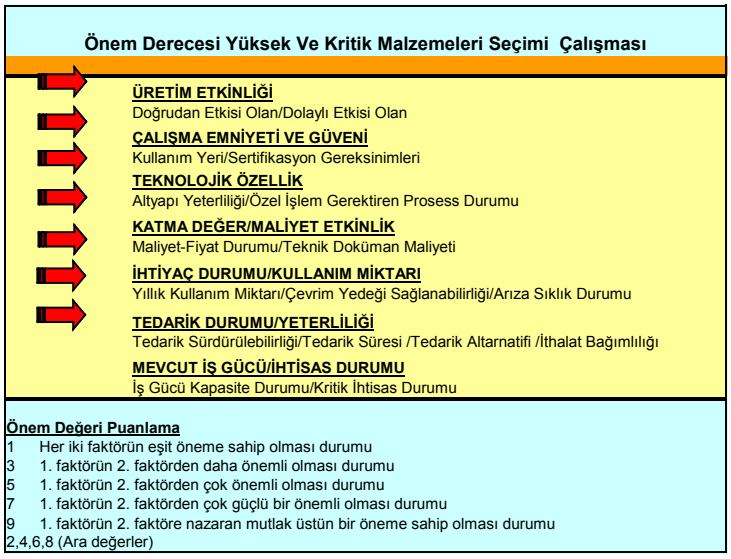

Şekil 2.26. Uzman personele gönderilen anket formu girişi.

UZMAN PERSONELE GÖNDERİLEN ANKET FORMU		TEKNOLOJİK ÖZELLİK Altyapı Yeterliliği/Özel İşlem Gerektiren Prosess Durumu	ÜRETİM ETKİNLİĞİ Doğrudan Etkisi Olan/Dolaylı Etkisi Olan	ÇALIŞMA EMNİYETİ VE GÜVENİ Kullanım Yeri/Sertifikasyon Gereksinimleri	KATMA DEĞER/MALİYET ETKİNLİK Maliyet-Fiyat Durumu/Teknik Doküman Maliyeti	İHTİYAÇ DURUMU/KULLANIM MİKTARI Yıllık Kullanım Miktarı/ Çevrim Yedeği Sağlanabilirliği /Arıza Sıklık Durumu	TEDARİK DURUMU/YETERLİLİĞİ Tedarik Sürdürülebilirliği/Tedarik Süresi /Tedarik Altarnatifi /İthalat Bağımlılığı	MEVCUT İŞ GÜCÜ/İHTİSAS DURUMU İş Gücü Kapasite Durumu/Kritik İhtisas Durumu
Yüksek Basınç Elemanları	Tamirlik Malzemeler							
Yüksek Basınç Elemanları	Kit ve Takım Malzemeler							
Yüksek Basınç Elemanları	Yedek Parça Grubu							
Yüksek Basınç Elemanları	Hammadde ve Sarf Malzemeler							
Yüksek Basınç Elemanları	Kontrol Üniteleri							
Tamirlik Malzemeler	Kit ve Takım Malzemeler							
Tamirlik Malzemeler	Yedek Parça Grubu							
Tamirlik Malzemeler	Hammadde ve Sarf Malzemeler							
Tamirlik Malzemeler	Kontrol Üniteleri							
Kit ve Takım Malzemeler	Yedek Parça Grubu							
Kit ve Takım Malzemeler	Hammadde ve Sarf Malzemeler							
Kit ve Takım Malzemeler	Kontrol Üniteleri							
Yedek Parça Grubu	Hammadde ve Sarf Malzemeler							
Yedek Parça Grubu	Kontrol Üniteleri							
Hammadde ve Sarf Malzemel	Kontrol Üniteleri							

Şekil 2.27. Uzman personele gönderilen anket formu

Uzman personelin yapmış olduğu derecelendirme Ek-2'de sunulmuş olup uzman personeli üretim etkinliğine yönelik vermiş oldukları puanlar Şekil 2.34'de sunulmuştur. Her teknoloji gurubuna ait karşılaştırma bu şekilde yapılmıştır.

AHP ANA SAYFA ÜRETİM ETKİNLİĞİ Doğrudan Etkisi Olan/Dolaylı Etkisi Olan		Uzman Personel-1	Uzman Personel-2	Uzman Personel-3	Uzman Personel-4	Uzman Personel-5	Uzman Personel-6	Uzman Personel-7	Uzman Personel-8	Uzman Personel-9
Yüksek Basınç Elemanları	Tamirlik Malzemeler	7.00	5.00	3.00	0.50	5.00	7.00	3.00	3.00	3.00
Yüksek Basınç Elemanları	Kit ve Takım Malzemeler	7.00	9.00	9.00	3.00	9.00	7.00	2.00	1.00	9.00
Yüksek Basınç Elemanları	Yedek Parça Grubu	7.00	5.00	3.00	3.00	5.00	7.00	1.00	1.00	3.00
Yüksek Basınç Elemanları	Hammadde ve Sarf Malzem	7.00	9.00	9.00	7.00	9.00	7.00	3.00	5.00	9.00
Yüksek Basınç Elemanları	Kontrol Üniteleri	5.00	5.00	5.00	3.00	5.00	5.00	2.00	7.00	5.00
Tamirlik Malzemeler	Kit ve Takım Malzemeler	5.00	5.00	5.00	3.00	5.00	5.00	1.00	1.00	5.00
Tamirlik Malzemeler	Yedek Parça Grubu	1.00	1.00	1.00	3.00	1.00	1.00	1.00	0.33	1.00
Tamirlik Malzemeler	Hammadde ve Sarf Malzem	5.00	7.00	7.00	3.00	7.00	5.00	2.00	5.00	7.00
Tamirlik Malzemeler	Kontrol Üniteleri	0.33	0.33	0.33	3.00	0.33	0.33	0.33	5.00	0.33
Kit ve Takım Malzemeler	Yedek Parça Grubu	0.33	0.33	0.33	0.20	0.33	0.33	1.00	0.33	0.33
Kit ve Takım Malzemeler	Hammadde ve Sarf Malzem	3.00	3.00	3.00	2.00	3.00	3.00	2.00	7.00	3.00
Kit ve Takım Malzemeler	Kontrol Üniteleri	0.14	0.14	0.20	7.00	0.14	0.14	1.00	3.00	0.20
Yedek Parça Grubu	Hammadde ve Sarf Malzem	3.00	5.00	5.00	3.00	5.00	3.00	2.00	7.00	5.00
Yedek Parça Grubu	Kontrol Üniteleri	0.33	0.33	0.33	3.00	0.33	0.33	1.00	5.00	0.33
Hammadde ve Sarf Malzem	Kontrol Üniteleri	0.14	0.14	0.14	3.00	0.14	0.14	0.50	0.33	0.14

Şekil 2.28 Üretim etkinliğine göre malzemelerin karşılaştırılması

AHP yöntemi ile malzeme gruplarının sıralamasında birden fazla uzman personelin görüşü alındığından uzman personelin yapmış oldukları derecelendirmelerin geometrik ortalaması alınmıştır.

Bu aşamadan sonra ise her bir değerlendirme kriterine göre karşılaştırma matrisleri hazırlanmıştır. Üretim malzemelerin karşılaştırma matrisleri sunulmuştur.

		A1	A2	A3	A4	A5	A6
		Yüksek Basınç Elemanları	Tamirlik Malzemeler	Kit ve Takım Malzemeler	Yedek Parça Grubu	Hammadde ve Sarf Malzemeler	Kontrol Üniteleri
A1	Yüksek Basınç Elemanları	1	3.32455	4.99308	3.17809	6.86252	4.42936
A2	Tamirlik Malzemeler	0.30079	1	3.30365	1.00000	4.95508	0.57489
A3	Kit ve Takım Malzemeler	0.20028	0.30270	1	0	3.01215	0.41304
A4	Yedek Parça Grubu	0.31465	1.00000	3	1	3.95404	0.64953
A5	Hammadde ve Sarf Malzemeler	0.14572	0.20181	0.33199	0.25291	1	0.25302
A6	Kontrol Üniteleri	0.22577	1.73947	2.42110	1.53959	3.95227	1

Şekil 2.29. Üretim etkinliği karşılaştırma matrisi

Tablo 2.1. Karşılaştırma kriterleri için tutarlılık göstergesi.

	Üretim etkinliği	Çalışma emniyeti ve güveni	Teknolojik özellik	Katma dğ./ maliyet etkinlik	İhtiyaç dr. /kullanım miktarı	Tedarik durumu /yeterliliği	Mevcut iş gücü /ihtisas durumu	
λ	6.25	6.32	6.21	6.18	6.19	6.26	6.15	
CI	0.05	0.06	0.04	0.04	0.04	0.05	0.03	
CR	0.04	0.05	0.03	0.03	0.03	0.04	0.02	<0,1

Bütün CR değerinin 0,10' dan küçük olması analiz işleminde herhangi bir hesaplama hatasının olmadığı karar vericilerin tutarlı karar verdikleri teyit edilmiştir.

Çalışma kapsamında üst kademe yöneticileri tarafından belirlenen ve kriterlerin birbirleri arsındaki önem dereceleri ile karşılaştırma matrisleri sonuçları çarpılarak toplanmıştır. Bu sayede işletmenin üst yönetimin AHP sürecine katılımı sağlanmıştır.

Tablo 2.2. AHP sonucunda malzemelerin önem sırası.

Malzeme Grubu	Önem Yüzdesi
Yüksek Basınç Elemanları	37%
Kontrol Üniteleri	22%
Yedek Parça Grubu	15%
Tamirlik Malzemeler	12%
Kit ve Takım Malzemeler	9%
Hammadde ve Sarf Malzemeler	5%

Bu aşamadan sonra yüksek basınç elemanları grubunda yer alan malzemeler ilişkin talep verileri yapay sinir ağlarının eğitiminden sonra veri üretimine yönelik kullanılacaktır. Yapay sinir ağlarının parti büyüklüğü metotları ile karşılaştırmasında söz konusu gruba ait veriler kullanılacaktır.

Ç. Optimum Çözümlerin Bulunması

Veriler en uygun çözümlerin bulunması amacı ile Wagner-Whitin algoritması kullanılmıştır. 186 stok kalemine beş yıllık veri 12'şerlik periyotlar halinde düzenlenmiştir. Tablo 2.3' de bu verilerden ilk 35'i sunulmuştur.

12 periyotluk hazırlanan veriler WinQSB programı kullanılarak optimum çözümleri bulunmuştur. Yapılan optimum çözümler ise ayrı bir tabloda saklanmıştır. WinQSB programı 1 setlik veri için çözümün nasıl yapıldığı kısaca değinilecektir.

WinQSB programına çözümü dört aşamalı olarak yapılabilmektedir. İlk aşamada stok problemini çözüm için kullanılacak Şekil 2.36'da görüleceği üzere metot seçilmektedir.

Tablo 2.3. Periyotlar halinde hazırlanan veriler.

			Periyot												Maliyetler		
S/N	Stok No	Yıl	1	2	3	4	5	6	7	8	9	10	11	12	S	H	V
1	XCK.32678	2005	5	3	46	43	47	39	34	1	49	22	12	24	345	9	142
2	XCK.32678	2006	34	9	34	30	1	21	35	26	45	19	22	0	378	10	155
3	XCK.32678	2007	45	48	6	43	22	32	29	40	24	17	22	3	411	11	169
4	XCK.32678	2008	3	1	1	12	24	17	38	29	14	43	2	5	454	12	187
5	XCK.32678	2009	39	21	18	9	15	25	10	10	39	30	41	32	482	13	198
6	XCK.01212	2005	2	40	3	23	32	41	29	11	13	18	5	3	385	13	125
7	XCK.01212	2006	36	44	5	24	44	11	47	43	3	4	33	47	422	15	137
8	XCK.01212	2007	16	33	11	46	25	47	1	15	22	37	12	42	459	16	149
9	XCK.01212	2008	2	25	27	13	38	35	10	40	9	42	1	17	507	17	165

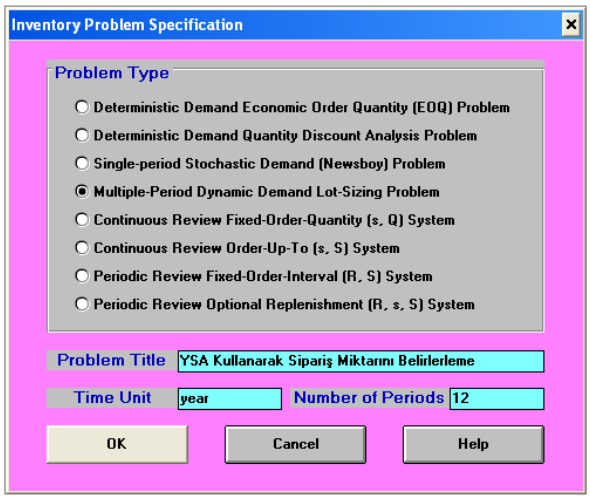

Şekil 2.30 Stok problemi için metot ve periyot seçimi

İkinci aşamada ise 12 periyot halindeki veri maliyetleri ile Şekil 2.37'deki gibi programa girilmektedir.

year	Demand	Setup Cost	Unit Variable Cost	Unit Holding Cost	Unit Backorder Cost
1	5	344	141	9	
2	3	344	141	9	
3	46	344	141	9	
4	43	344	141	9	
5	47	344	141	9	
6	39	344	141	9	
7	34	344	141	9	
8	1	344	141	9	
9	49	344	141	9	
10	22	344	141	9	
11	12	344	141	9	
12	24	344	141	9	

Şekil 2.31 Verilerin WinQSB programına girilmesi

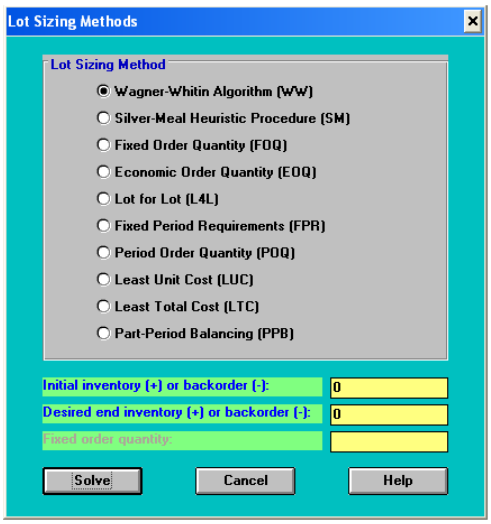

Şekil 2.32. Problemin çözümü için algoritmanın seçilmesi

Üçüncü aşamada "solve" problem komutu verilmektedir. Şekil 2.38 sunulan ara yüzden stok programında kullanılacak algoritmanın seçimi yapılmaktadır. "Solve" komutu verilerek programın çözüm işlemi gerçekleştirilmesi sağlanmaktadır.

12-11-2010 year	Demand	Production (Lot Size)	Setup	Expected Inventory	Expected Backorder	Cumulative Cost
Initial				0		
1	5,0000	8,0000	Yes	3,0000	0	$1499,0000
2	3,0000	0	No	0	0	$1499,0000
3	46,0000	46,0000	Yes	0	0	$8329,0000
4	43,0000	43,0000	Yes	0	0	$14736,0000
5	47,0000	47,0000	Yes	0	0	$21707,0000
6	39,0000	74,0000	Yes	35,0000	0	$32800,0000
7	34,0000	0	No	1,0000	0	$32809,0000
8	1,0000	0	No	0	0	$32809,0000
9	49,0000	71,0000	Yes	22,0000	0	$43362,0000
10	22,0000	0	No	0	0	$43362,0000
11	12,0000	36,0000	Yes	24,0000	0	$48998,0000
12	24,0000	0	No	0	0	$48998,0000
	Solution	Method:	WW		Total Cost =	$48998,0000

Şekil 2.33 WW çözümü

Şekil 2.39'da ise programın Wagner-Whitin yöntemi ile çözümü parti büyüklüğü çözümleri ekrana gelmektedir. Elde edilen bu verilen ayrı bir Excel tablosunda tutulmuştur. Ara geçişler ve hesaplamalar için Visual Basic makro dili kullanılmıştır. Tez çalışmasın kapsamında yazılan kodlar Ek-3'de sunulmuştur. Bu sayede yapay sinir ağlarının eğitiminde kullanılacak olan veriler hazırlanmıştır. İlk 80 verinin optimum çözümleri Tablo 2.5. de sunulmuştur.

Tablo 2.4 Wagner-Whitin yöntemi optimum çözümlerin gösterilmesi.

S/N	Talepler												Maliyet			WW Çözümü											
	1	2	3	4	5	6	7	8	9	10	11	12	S	V	H	1	2	3	4	5	6	7	8	9	10	11	12
1	5	3	46	43	47	39	34	1	49	22	12	24	344	141	9	8	0	46	43	47	74	0	0	71	0	36	0
2	34	9	34	30	1	21	35	26	45	19	22	0	378	155	9	43	0	65	0	0	21	61	0	64	0	22	0
3	45	48	6	43	22	32	29	40	24	17	22	3	411	169	10	45	54	0	65	0	61	0	64	0	42	0	0
4	3	1	1	12	24	17	38	29	14	43	2	5	454	186	11	17	0	0	0	41	0	38	43	0	50	0	0
5	39	21	18	9	15	25	10	10	39	30	41	32	482	198	12	60	0	42	0	0	45	0	0	69	0	73	0
6	2	40	3	23	32	41	29	11	13	18	5	3	385	125	13	2	43	0	23	32	41	40	0	39	0	0	0
7	36	44	5	24	44	11	47	43	3	4	33	47	421	137	14	36	49	0	24	55	0	47	50	0	0	33	47
8	16	33	11	46	25	47	1	15	22	37	12	42	459	149	15	16	44	0	71	0	48	0	37	0	49	0	42
9	2	25	27	13	38	35	10	40	9	42	1	17	506	164	17	27	0	40	0	38	45	0	49	0	43	0	17
10	45	48	4	44	1	48	21	42	6	38	36	20	538	174	18	45	52	0	45	0	69	0	48	0	38	56	0
11	12	13	47	41	20	2	40	38	16	5	46	48	332	80	13	25	0	47	63	0	0	40	59	0	0	46	48
12	15	37	45	10	38	20	16	41	49	9	16	3	364	88	14	15	37	55	0	38	36	0	41	58	0	19	0
13	43	35	23	49	26	33	30	16	7	33	40	24	396	96	16	43	58	0	49	26	33	53	0	0	33	64	0
14	47	31	17	5	6	26	44	45	39	36	44	26	437	106	17	47	31	28	0	0	26	44	45	39	36	44	26
15	46	9	7	3	36	9	42	4	0	1	43	29	464	113	18	65	0	0	0	45	0	47	0	0	0	43	29
16	11	48	15	37	46	17	19	20	24	36	32	35	357	108	18	11	63	0	37	63	0	19	20	24	36	32	35
17	49	20	46	36	7	40	12	22	33	22	24	12	392	119	20	49	20	46	43	0	52	0	22	33	22	36	0
18	28	36	26	3	29	27	34	18	35	43	18	24	426	129	22	28	36	29	0	29	27	52	0	35	61	0	24
19	26	4	0	9	34	2	40	13	9	14	24	36	471	143	24	30	0	0	9	36	0	53	0	23	0	24	36
20	3	2	4	45	20	18	24	14	3	1	35	15	500	152	26	681	0	0	0	0	0	0	0	0	0	0	0
21	16	38	44	31	31	17	30	23	48	28	43	18	395	132	21	16	38	44	31	48	0	30	23	48	28	61	0
22	6	6	47	17	28	8	43	41	15	23	10	31	433	145	23	12	0	64	0	36	0	43	56	0	33	0	31
23	15	14	28	1	15	9	12	47	21	26	33	41	471	158	26	29	0	29	0	24	0	12	47	21	26	33	41
24	32	1	43	34	3	39	14	25	15	36	41	32	521	174	28	33	0	43	37	0	53	0	40	0	36	41	32
25	11	14	0	10	16	28	22	10	36	40	38	45	553	185	30	25	0	0	26	0	28	32	0	36	40	38	45
26	6	36	17	39	40	8	5	36	24	8	20	31	330	131	15	6	53	0	39	53	0	0	36	32	0	20	31
27	2	35	45	15	6	27	14	26	18	22	39	17	362	144	16	2	35	66	0	0	41	0	44	0	22	56	0
28	47	36	6	1	4	8	2	15	46	39	42	32	394	157	17	47	43	0	0	14	0	0	15	46	39	42	32
29	1	1	27	8	49	4	39	21	29	0	0	13	435	173	19	2	0	35	0	53	0	60	0	29	0	0	13

D. Yapay Sinir Ağlarının Eğitimi

Yapay sinir ağlarının eğitimi için kullanılan veriler sipariş planına dönüştürülmüştür. Tablo 2.4'de en uygun çözümleri sunulan verilerin Tablo 2.5'de sipariş planına dönüştürülmüş hali görülmektedir.

	Demands												MALİYET			WW ÇÖZÜMLERİ												NORMALİZE EDİLMİŞ ÇÖZÜMLER											
S/N	1	2	3	4	5	6	7	8	9	10	11	12	S	V	H	1	2	3	4	5	6	7	8	9	10	11	12	1	2	3	4	5	6	7	8	9	10	11	12
1	5	3	46	43	47	39	34	1	49	22	12	24	344	141	9	8	0	46	43	47	74	0	0	71	0	36	0	1	0	1	1	1	1	0	0	1	0	1	0
2	34	9	34	30	1	21	35	26	45	19	22	0	378	155	9	43	0	65	0	0	21	61	0	64	0	22	0	1	0	1	0	0	1	1	0	1	0	1	0
3	45	48	6	43	22	32	29	40	24	17	22	3	411	169	10	45	54	0	65	0	61	0	64	0	42	0	0	1	1	0	1	0	1	0	1	0	1	0	0
4	3	1	1	12	24	17	38	29	14	43	2	5	454	186	11	17	0	0	0	41	0	38	43	0	50	0	0	1	0	0	0	1	0	1	1	0	1	0	0
5	39	21	18	9	15	25	10	10	39	30	41	32	482	198	12	60	0	42	0	0	45	0	0	69	0	73	0	1	0	1	0	0	1	0	0	1	0	1	0
6	2	40	3	23	32	41	29	11	13	18	5	3	385	125	13	2	43	0	23	32	41	40	0	39	0	0	0	1	1	0	1	1	1	1	0	1	0	0	0
7	36	44	5	24	44	11	47	43	3	4	33	47	421	137	14	36	49	0	24	55	0	47	50	0	0	33	47	1	1	0	1	1	0	1	1	0	0	1	1
8	16	33	11	46	25	47	1	15	22	37	12	42	459	149	15	16	44	0	71	0	48	0	37	0	49	0	42	1	1	0	1	0	1	0	1	0	1	0	1
9	2	25	27	13	38	35	10	40	9	42	1	17	506	164	17	27	0	40	0	38	45	0	49	0	43	0	17	1	0	1	0	1	1	0	1	0	1	0	1
10	45	48	4	44	1	48	21	42	6	38	36	20	538	174	18	45	52	0	45	0	69	0	48	0	38	56	0	1	1	0	1	0	1	0	1	0	1	1	0
11	12	13	47	41	20	2	40	38	16	5	46	48	332	80	13	25	0	47	63	0	0	40	59	0	0	46	48	1	0	1	1	0	0	1	1	0	0	1	1
12	15	37	45	10	38	20	16	41	49	9	16	3	364	88	14	15	37	55	0	38	36	0	41	58	0	19	0	1	1	1	0	1	1	0	1	1	0	1	0
13	43	35	23	49	26	33	30	16	7	33	40	24	396	96	16	43	58	0	49	26	33	53	0	0	33	64	0	1	1	0	1	1	1	1	0	0	1	1	0
14	47	31	17	5	6	26	44	45	39	36	44	26	437	106	17	47	31	28	0	0	26	44	45	39	36	44	26	1	1	1	0	0	1	1	1	1	1	1	1
15	46	9	7	3	36	9	42	4	0	1	43	29	464	113	18	65	0	0	0	45	0	47	0	0	0	43	29	1	0	0	0	0	1	0	1	0	0	0	1
16	11	48	15	37	46	17	19	20	24	36	32	35	357	108	18	11	63	0	37	63	0	19	20	24	36	32	35	1	1	0	1	1	0	1	1	1	1	1	1
17	49	20	46	36	7	40	12	22	33	22	24	12	392	119	20	49	20	46	43	0	52	0	22	33	22	36	0	1	1	1	1	0	1	0	1	1	1	1	0
18	28	36	26	3	29	27	34	18	35	43	18	24	426	129	22	28	36	29	0	29	27	52	0	35	61	0	24	1	1	1	0	1	1	1	0	1	1	0	1
19	26	4	0	9	34	2	40	13	9	14	24	36	471	143	24	30	0	0	9	36	0	53	0	23	0	24	36	1	0	0	1	1	0	1	0	1	0	1	1
20	3	2	4	45	20	18	24	14	3	1	35	15	500	152	26	681	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0
21	16	38	44	31	31	17	30	23	48	28	43	18	395	132	21	16	38	44	31	48	0	30	23	48	28	61	0	1	1	1	1	1	0	1	1	1	1	1	0
22	6	6	47	17	28	8	43	41	15	23	10	31	433	145	23	12	0	64	0	36	0	43	56	0	33	0	31	1	0	1	0	1	0	1	1	0	1	0	1
23	15	14	28	1	15	9	12	47	21	26	33	41	471	158	26	29	0	29	0	24	0	12	47	21	26	33	41	1	0	1	0	1	0	1	1	1	1	1	1
24	32	1	43	34	3	39	14	25	15	36	41	32	521	174	28	33	0	43	37	0	53	0	40	0	36	41	32	1	0	1	1	0	1	0	1	0	1	1	1
25	11	14	0	10	16	28	22	10	36	40	38	45	553	185	30	25	0	0	26	0	28	32	0	36	40	38	45	1	0	0	1	0	1	1	0	1	1	1	1
26	6	36	17	39	40	8	5	36	24	8	20	31	330	131	15	6	53	0	39	53	0	0	36	32	0	20	31	1	1	0	1	1	1	0	1	1	0	1	1
27	2	35	45	15	6	27	14	26	18	22	39	17	362	144	16	2	35	66	0	0	41	0	44	0	22	56	0	1	1	1	0	0	1	0	1	0	1	1	0
28	47	36	6	1	4	8	2	15	46	39	42	32	394	157	17	47	43	0	0	14	0	0	15	46	39	42	32	1	1	0	0	1	0	0	1	1	1	1	1
29	1	1	27	8	49	4	39	21	29	0	0	13	435	173	19	2	0	35	0	53	0	60	0	29	0	0	13	1	0	1	0	0	1	0	1	0	0	0	1
30	8	32	45	6	13	40	10	26	40	34	31	34	462	184	21	8	32	51	0	13	50	0	26	40	34	31	34	1	1	1	0	1	1	0	1	1	1	1	1
31	14	28	31	28	33	34	22	0	14	31	34	4	367	119	13	42	0	59	0	33	56	0	0	14	31	38	0	1	0	1	0	1	1	0	0	1	1	1	0
32	16	5	23	39	49	8	26	20	24	12	28	3	403	130	14	21	0	23	39	57	0	46	0	36	0	31	0	1	0	1	1	1	0	1	0	1	0	1	0
33	25	16	5	34	47	2	28	14	22	6	34	48	438	141	15	46	0	0	34	49	0	42	0	28	0	34	48	1	0	0	1	1	0	1	0	1	0	1	1
34	15	28	16	5	2	17	22	47	26	23	40	12	484	156	17	15	51	0	0	0	39	0	47	49	0	52	0	1	1	0	0	0	1	0	1	1	0	1	0
35	36	7	10	1	49	16	40	34	24	37	41	13	513	166	18	54	0	0	0	65	0	40	58	0	37	54	0	1	0	0	0	1	0	1	1	0	1	1	0
36	34	23	24	33	24	27	10	38	5	21	9	6	354	127	19	34	23	24	33	24	37	0	43	0	36	0	0	1	1	1	1	1	1	0	1	0	1	0	0
37	46	13	6	37	1	25	27	45	46	21	41	29	388	139	21	46	19	0	38	0	25	27	45	46	21	41	29	1	1	0	1	0	1	1	1	1	1	1	1
38	43	42	36	39	15	42	27	27	35	43	2	10	422	151	23	43	42	36	54	0	42	27	27	35	45	0	10	1	1	1	1	0	1	1	1	1	1	0	1
39	38	33	16	48	9	3	0	2	12	13	30	26	466	167	25	38	49	0	62	0	0	0	0	25	0	30	26	1	1	0	1	0	0	0	0	1	0	1	1
40	5	18	4	17	36	40	34	14	23	35	19	17	495	178	27	5	22	0	17	36	40	48	0	23	35	36	0	1	1	0	1	1	1	1	0	1	1	1	0
41	12	30	9	13	47	14	43	20	2	37	41	41	352	101	12	12	52	0	0	61	0	65	0	0	37	41	41	1	1	0	0	1	0	1	0	0	1	1	1
42	36	21	10	25	26	34	14	47	30	41	36	24	386	111	13	36	31	0	51	0	48	0	47	30	41	60	0	1	1	0	1	0	1	0	1	1	1	1	0
43	32	14	11	32	21	20	48	24	42	10	28	17	420	120	14	57	0	0	32	41	0	72	0	52	0	45	0	1	0	0	1	1	0	1	0	1	0	1	0
44	15	38	48	6	28	48	3	36	34	7	12	42	464	133	16	15	38	54	0	28	51	0	36	53	0	0	42	1	1	1	0	1	1	0	1	1	0	0	1
45	19	34	34	41	35	12	45	8	9	16	19	49	492	141	17	19	34	34	41	47	0	62	0	0	35	0	49	1	1	1	1	1	0	1	0	0	1	0	1
46	7	4	15	15	34	27	3	42	23	20	38	11	338	99	10	11	0	30	0	64	0	0	42	43	0	49	0	1	0	1	0	1	0	0	1	1	0	1	0
47	13	9	42	40	10	8	49	1	7	40	37	37	370	108	11	22	0	42	58	0	0	57	0	0	40	37	37	1	0	1	1	0	0	1	0	0	1	1	1
48	15	34	6	37	3	26	11	16	12	6	34	15	403	118	11	15	40	0	40	0	37	0	34	0	0	49	0	1	1	0	1	0	1	0	1	0	0	1	0
49	0	17	49	0	2	6	1	23	26	14	42	11	445	130	13	0	17	58	0	0	0	0	23	40	0	53	0	0	1	1	0	0	0	0	1	1	0	1	0
50	18	10	4	25	42	48	29	9	34	9	31	17	472	138	14	32	0	0	25	42	48	38	0	43	0	48	0	1	0	0	1	1	1	1	0	1	0	1	0
51	17	20	15	16	4	41	26	39	34	43	18	49	401	109	9	37	0	35	0	0	67	0	73	0	61	0	49	1	0	1	0	0	0	1	0	1	0	1	0
52	29	34	6	39	16	11	44	33	43	17	2	36	440	119	10	69	0	0	66	0	0	77	0	62	0	0	36	1	0	0	1	0	0	1	0	1	0	0	1
53	37	33	44	23	7	7	29	36	18	32	33	4	479	130	11	70	0	81	0	0	0	29	54	0	69	0	0	1	0	1	0	0	0	1	1	0	1	0	0
54	10	13	0	40	37	46	3	36	47	25	33	19	529	144	12	23	0	0	77	0	49	0	36	72	0	52	0	1	0	0	1	0	1	0	1	1	0	1	0
55	40	21	33	8	28	29	9	47	5	21	15	44	561	152	13	61	0	41	0	66	0	0	52	0	36	0	44	1	0	1	0	1	0	0	1	0	1	0	1
56	5	6	5	26	3	37	18	25	36	43	22	17	348	130	19	16	0	0	29	0	55	0	25	36	43	39	0	1	0	0	1	0	1	0	1	1	1	1	0
57	43	10	38	21	8	31	17	44	2	11	20	17	382	143	21	53	0	38	29	0	48	0	46	0	11	37	0	1	0	1	1	0	1	0	1	0	1	1	0
58	25	34	36	16	38	22	46	7	2	27	1	44	415	156	23	25	34	52	0	38	22	55	0	0	28	0	44	1	1	1	0	1	1	1	0	0	1	0	1
59	47	31	49	2	23	4	42	0	19	11	1	5	459	172	25	47	31	51	0	27	0	42	0	36	0	0	0	1	1	1	0	1	0	1	0	1	0	0	0
60	40	28	1	46	45	48	34	42	9	18	5	4	487	183	27	40	29	0	46	45	48	34	51	0	27	0	0	1	1	0	1	1	1	1	1	0	1	0	0
61	33	27	12	18	34	49	15	17	39	2	22	2	341	88	18	33	39	0	18	34	64	0	17	41	0	24	0	1	1	0	1	1	1	0	1	1	0	1	0
62	23	39	7	35	43	30	32	43	39	8	49	36	373	97	20	23	46	0	35	43	30	32	43	47	0	49	36	1	1	0	1	1	1	1	1	1	0	1	1
63	47	22	23	3	47	17	37	21	22	49	2	22	406	105	21	47	22	26	0	64	0	37	21	22	51	0	22	1	1	1	0	1	0	1	1	1	1	0	1
64	27	36	3	34	28	3	16	39	44	31	11	42	449	116	24	27	39	0	34	31	0	16	39	44	42	0	42	1	1	0	1	1	0	1	1	1	1	0	1
65	26	42	33	24	35	32	42	7	28	10	40	35	476	123	25	26	42	33	24	35	32	49	0	38	0	40	35	1	1	1	1	1	1	1	0	1	0	1	1
66	19	36	30	26	44	43	3	0	20	26	25	28	387	118	14	19	36	56	0	44	46	0	0	20	51	0	28	1	1	1	0	1	1	0	0	1	1	0	1
67	7	34	32	34	24	41	42	13	31	40	37	31	425	130	15	7	34	32	58	0	41	55	0	31	40	37	31	1	1	1	1	0	1	1	0	1	1	1	1
68	34	24	22	25	21	45	30	35	44	35	8	38	462	141	16	34	46	0	46	0	45	30	35	44	43	0	38	1	1	0	1	0	1	1	1	1	1	0	1
69	14	7	34	18	33	8	12	36	3	28	36	36	510	156	18	21	0	52	0	53	0	0	39	0	28	36	36	1	0	1	0	1	0	0	1	0	1	1	1
70	44	20	17	25	25	6	40	40	6	23	8	47	542	166	19	64	0	42	0	31	0	40	46	0	31	0	47	1	0	1	0	1	0	1	1	0	1	0	1
71	26	41	29	9	32	1	16	36	10	8	37	9	379	82	9	26	79	0	0	49	0	0	54	0	0	46	0	1	1	0	0	1	0	0	1	0	0	1	0
72	28	17	44	30	33	26	40	2	35	37	13	21	415	90	10	45	0	74	0	59	0	42	0	35	50	0	21	1	0	1	0	1	0	1	0	1	1	0	1
73	25	36	49	14	44	31	15	45	32	13	31	48	451	98	11	61	0	63	0	44	46	0	45	45	0	31	48	1	0	1	0	1	1	0	1	1	0	1	1
74	41	2	14	47	12	29	25	31	14	19	6	40	498	109	12	57	0	0	59	0	54	0	45	0	25	0	40	1	0	0	1	0	1	0	1	0	1	0	1
75	49	47	26	3	2	35	2	21	22	3	20	20	529	115	13	49	78	0	0	0	37	0	46	0	0	40	0	1	1	0	0	0	1	1	0	0	0	1	0
76	46	30	20	13	47	49	39	41	44	32	20	26	342	109	17	46	30	33	0	47	49	39	41	44	52	0	26	1	1	1	0	0	1	1	1	1	1	0	1
77	46	0	11	49	32	13	37	17	22	26	45	17	375	119	18	46	0	11	49	45	0	54	0	22	26	62	0	1	0	1	1	1	0	1	0	1	1	1	0
78	15	47	27	34	20	13	34	11	40	17	5	0	408	130	20	15	47	27	34	33	0	45	0	40	22	0	0	1	1	1	1	1	0	1	0	1	1	0	0
79	41	49	46	14	14	5	43	42	43	45	6	2	451	144	22	41	49	60	0	19	0	43	42	43	53	0	0	1	1	1	0	1	0	1	1	1	1	0	0
80	24	31	6	5	23	29	48	16	3	37	11	30	478	152	23	24	42	0	0	23	29	67	0	0	48	0	30	1	1	0	0	1	1	1	0	0	1	0	1

Tablo 2.5. Sipariş planına dönüştürülmüş veriler

$$E = \begin{bmatrix} D_{1x1} & D_{1x2} & \cdots & D_{1x12} & S_1 & V_1 & H_1 & O_{1x1} & O_{1x2} & \cdots & O_{1x12} \\ D_{2x1} & D_{2x2} & \cdots & D_{2x12} & S_2 & V_2 & H_2 & O_{2x1} & O_{2x2} & \cdots & O_{2x12} \\ \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \\ \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \\ \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \\ D_{500x1} & D_{500x2} & \cdots & D_{500x12} & S_{500} & V_{500} & H_{500} & O_{500x1} & O_{500x2} & \cdots & O_{500x12} \\ \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \\ \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \\ \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \\ D_{800x1} & D_{800x2} & \cdots & D_{800x12} & S_{800} & V_{800} & H_{800} & O_{800x1} & O_{800x2} & \cdots & O_{800x12} \\ \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \\ \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \\ D_{923x1} & D_{923x1} & \cdots & D_{923x1} & S_{923} & V_{923} & H_{923} & O_{923x1} & O_{923x2} & \cdots & O_{923x12} \end{bmatrix}$$

Şekil 2.34. YSA eğitiminde kullanılan verilerin ayrımı

Verilerin sipariş planına dönüştürülmesinden sonra elimizde 923 satır sayısına 27 sütun sayısına sahip 923x27 lik bir matris elde etmiş olduk. 923 satırlık veri 186 faklı malzemeye ait 5 yıllık olmak üzer 2005-2009 yıllarına ait verilerdir. Her malzemenin bir yıla ait verisi 1 satırla ifade edilmiştir. 27 sütun ise bir yıla ilişkin 12 dönemlik (aylık) veri, 3 sütun halinde maliyet verisi (elde bulundurma maliyeti, hazırlık maliyeti, değişken maliyetler) ve 12 sütun halindeki sipariş planına dönüştürülmüş Wagner-Whitin çözümleridir.

D: Talepler
S: Hazırlık maliyetler
V: Değişken maliyetler
H: Elde bulundurma maliyetleri
O: Sipariş büyüklüleri (1,0)

Gösterecek şekilde Şekil 2.37. sunulduğu gibi talepler, maliyetler ve sipariş büyüklüklerinin yer aldığı matris elde edilmiştir.

YSA eğitimi için ilk n_{1x1} ve n_{800x15} arasındaki veriler girdi (input) olarak verilmiştir. n_{1x16} ve n_{800x27} arasındaki veriler YSA eğitim hedeflenen (desired) olarak ağa tanıtılmıştır. Sisteme ayrıca test verisi verilmemiştir. Girdi havuzundaki verilerin %5 kullanılmak üzere Nero Solution programı ayarlanmıştır. n_{801x1} ve n_{930x15} arasındaki datalar veri üretim işlemlerinde input, n_{801x16} ve n_{930x27} arasındaki datalar veri üretim işlemlerinde desired olarak ağa tanıtılmıştır.

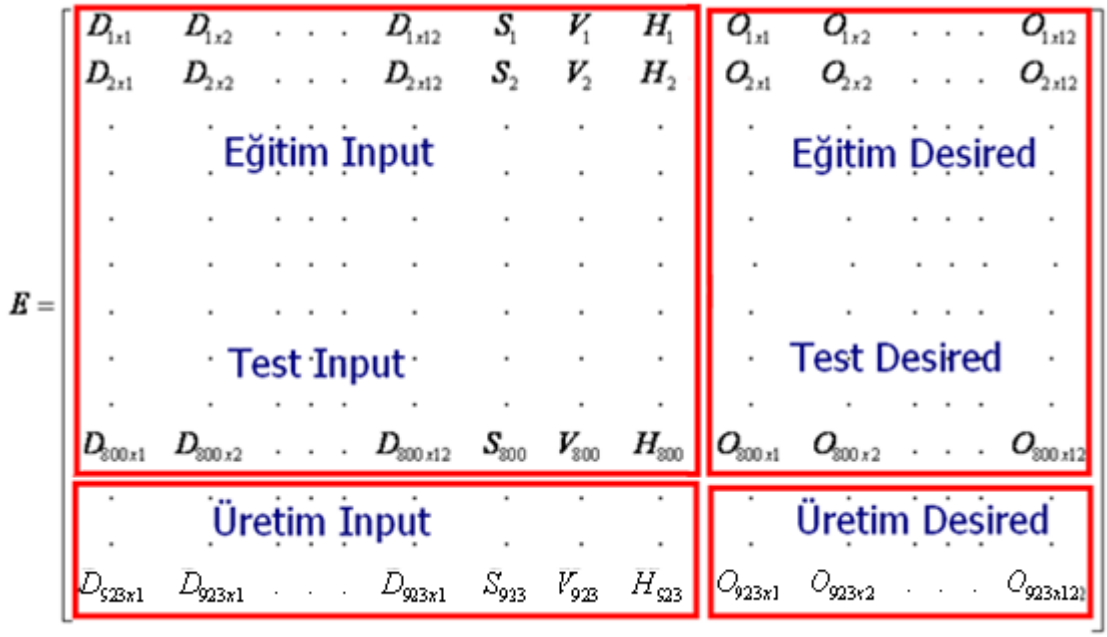

Şekil 2.35 YSA eğitiminde verilerin sınıflandırılması

Holger R. M. ve arkadaşlarının 1999 yapmış oldukları çalışmada gizli katmanda bulunması gereken düğüm noktası sayısı deneme yanılma yöntemi ile bulunabileceği gibi sistematik bir yönteminde belirlenebileceği bildirilmiştir [52]. Girdi katmanındaki düşüm sayılarının girdi sayısına eşit olması, çıktı katmanındaki düğüm sayısının çıktı sayısına eşit olabileceği değerlendirilmiştir. Bu tez çalışmasında; yapay sinir ağları oluşturulurken dikkate alınan ağ mimarisi şu şekildedir. Girdi(girdiler bir yıla ait 12 dönemlik talep, elde bulundurma maliyeti, hazırlık maliyeti ve değişken maliyetler olmak üzere 3 maliyet girdisi) sayısına eşit girdi katmanında 15 düğüm oluşturulmuştur. Seminer çalışmasından elde edilen tecrübe doğrultusunda girdi katmanındaki düğüm sayısının iki katı olmak üzere gizli katmanda 30 düğüm

oluşturulmuştur. Çıktı katmanına ise çıktı sayısına eşit 12 düğüm esas alınarak ağlar oluşturulmuştur.

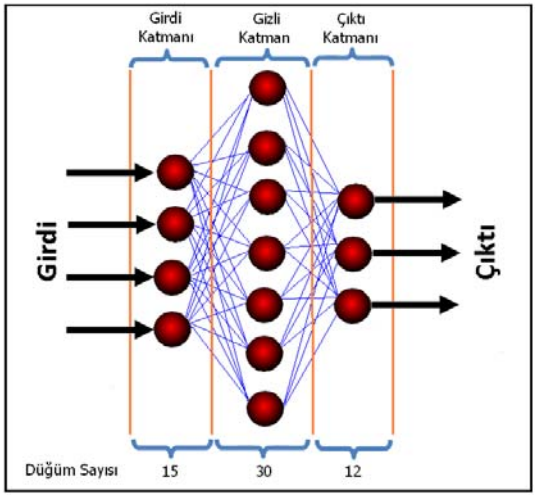

Şekil 2.36. Eğitilen ağların genel yapısı

Genel hatları ile ağ mimarisi oluşturulduktan sonra NeuroSolutions 4 programı vasıtası ile ağların eğitim işlemlerine başlanmıştır. Eğitim işlemleri esnasında 40 adet çok katmanlı ağ, 240 radyal tabanlı yapay sinir ağı ve 120 adet Kohonen ağın eğitimi yapılmıştır. Ağların eğitim işlemlerinde sistematik olarak NeuroSolutions 4 programının izin verdiği ağ yapısına ilişkin transfer fonksiyonu, öğrenme kuralı, karşılaştırma kuralı, komşuluk ilişkisi gibi faktörler göz önüne alınarak yapay sinir ağları oluşturulmuştur. Tablo 2.7'de eğitilen çok katmanlı ağ yapılarından örmekler sunulmuştur.

Tablo 2.6. Eğitilen çok katmanlı yapay sinir ağı modelleri

	Data	Cros Validaton And Test	Layers	Hidden Layer Property	Output Layer Property	Learning Control	Statistic
1	Input 800 Desired 800	CV :%5 Test :%5 Prod. 130	Input Layer Node :15 Hidden Layer Node :30 Output Layer Node :12	Processing Element :30 Transfer Function :TanhAxon Learningg Rule :Momentum __Step Size :1 __Momentum :0,7	Processing Element :30 Transfer Function :TanhAxon Learningg Rule :Momentum __Step Size :1 __Momentum :0,7	Maximum Epochs :10000 Termination :Minimum ThreShold :0,01 Load Best On Test :True Weight Update :Batch	L. Time 1,44 min. L. Epochs 3.904
2	Data	CV and Test	Layers	Hidden Layer Property	Hidden Layer Property	Learning Control	Statistic
	Input 800 Desired 800	CV :%5 Test :%5 Prod. 130	Input Layer Node :15 Hidden Layer Node :30 Output Layer Node :12	Processing Element :30 Transfer Function :Sigmoid Axon Learningg Rule :Momentum __Step Size :1 __Momentum :0,7	Processing Element :30 Transfer Function :Sigmoid Axon Learningg Rule :Momentum __Step Size :1 __Momentum :0,7	Maximum Epochs :10000 Termination :Minimum ThreShold :0,01 Load Best On Test :True Weight Update :Batch	L. Time 4,07 min. L. Epochs 10.000
3	Data	CV and Test	Layers	Hidden Layer Property	Hidden Layer Property	Learning Control	Statistic
	Input 800 Desired 800	CV :%5 Test :%5 Prod. 130	Input Layer Node :15 Hidden Layer Node :30 Output Layer Node :12	Processing Element :30 Transfer Function :Linear TanhAxon Learningg Rule :Momentum __Step Size :1 __Momentum :0,7	Processing Element :30 Transfer Function :Linear TanhAxon Learningg Rule :Momentum __Step Size :1 __Momentum :0,7	Maximum Epochs :10000 Termination :Minimum ThreShold :0,01 Load Best On Test :True Weight Update :Batch	L. Time 3,48 min. L. Epochs 10.000
4	Data	CV and Test	Layers	Hidden Layer Property	Hidden Layer Property	Learning Control	Statistic
	Input 800 Desired 800	CV :%5 Test :%5 Prod. 130	Input Layer Node :15 Hidden Layer Node :30 Output Layer Node :12	Processing Element :30 Transfer Function :Linear SigmoidAx Learningg Rule :Momentum __Step Size :1 __Momentum :0,7	Processing Element :30 Transfer Function :Linear SigmoidAxon Learningg Rule :Momentum __Step Size :1 __Momentum :0,7	Maximum Epochs :10000 Termination :Minimum ThreShold :0,01 Load Best On Test :True Weight Update :Batch	L. Time 4,14 min. L. Epochs 10.000
5	Data	CV and Test	Layers	Hidden Layer Property	Hidden Layer Property	Learning Control	Statistic
	Input 800 Desired 800	CV :%5 Test :%5 Prod. 130	Input Layer Node :15 Hidden Layer Node :30 Output Layer Node :12	Processing Element :30 Transfer Function :Soft MaxAxon Learningg Rule :Momentum __Step Size :1 __Momentum :0,7	Processing Element :30 Transfer Function :Soft MaxAxon Learningg Rule :Momentum __Step Size :1 __Momentum :0,7	Maximum Epochs :10000 Termination :Minimum ThreShold :0,01 Load Best On Test :True Weight Update :Batch	L. Time 4,14 min. L. Epochs 10.000

NeuroSolutions 4 programı öğrenme kuralı olarak 5 farklı tipte öğrenme kuralını, 8 farklı tipte transfer fonksiyonunu desteklemektedir. Kendinden öğrenmeli ağlarda ayrıca 3 farklı tipte komşuluk ilişkisini desteklemektedir. Ayrıca radyanlı tabanlı ağlar için 2 farklı tipte karşılaştırma kuralını ve 3 farklı metrik faktörü desteklemektedir. Çok katmanlı ağlar oluşturulurken 8 tip transfer fonksiyonu 5 farklı öğrenme kuralında 40 farklı tip yapay sinir ağı oluşturulmuştur. Bu faktörlerin tipleri Tablo 2.7'de sunulmuştur.

Tablo 2.7. Çok katmanlı ağ oluşturulurken dikkate alınan faktörler

Transfer Fonksiyonunu	Öğrenme Kuralı
Axon	ConjugateGradiant
BiasAxon	DeltaBarDelta
Linear SigmoidAxon	Momentum
Linear TanhAxon	QuickProp
LinearAxon	Step
Sigmoid Axon	
Soft MaxAxon	
TanhAxon	

Kendinden öğrenmeli ağlar oluşturulurken 8 tip transfer fonksiyonu, 5 farklı öğrenme kuralında, 3 farklı komşuluk ilişkisine sahip 120 farklı tip yapay sinir ağı oluşturulmuştur. Bu faktörlerin tipleri Tablo 2.8'de sunulmuştur.

Tablo 2.8. Kendinden öğrenmeli ağ oluşturulurken dikkate alınan faktörler

Transfer Fonksiyonunu	Öğrenme Kuralı	Komşuluk İlişkisi
Axon	ConjugateGradiant	DiomendKohonenFull
BiasAxon	DeltaBarDelta	LinedKohonenFull
Linear SigmoidAxon	Momentum	SequreKohonenFull
Linear TanhAxon	QuickProp	
LinearAxon	Step	
Sigmoid Axon		
Soft MaxAxon		
TanhAxon		

Radyal tabanlı oluşturulurken 8 tip transfer fonksiyonu, 5 farklı öğrenme kuralında, 2 farklı karşılaştırma kuralı, 3 farklı metrik faktöre bağlı olmak üzere 240 farklı tip yapay sinir ağı oluşturulmuştur. Bu faktörlerin tipleri Tablo 2.9'da sunulmuştur.

Tablo 2.9. Radyal tabanlı ağ oluşturulurken dikkate alınan faktörler

Transfer Fonksiyonunu	Öğrenme Kuralı	Karşılaştırma Kuralı	Metrik Faktörü
Axon	ConjugateGradiant	ConscienceFull	DotProduct
BiasAxon	DeltaBarDelta	StandartFulll	Euclidian
Linear	Momentum		BoxCar
SigmoidAxon	QuickProp		
Linear TanhAxon	Step		
LinearAxon			
Sigmoid Axon			
Soft MaxAxon			
TanhAxon			

Bu sayede 40 tane çok katmanlı yapay sinir ağı, 120 tane kendinden öğrenmeli yapay sinir ağı ve 240 tane radyal tabanlı yapay sinir ağı oluşturulmuş ve her yapıya bir ağ numarası atanmıştır. Ağ numarası bazında eğitilen yapay sinir ağlarının transfer fonksiyonu, öğrenme kuralı vs. özellikleri Ek-4'de sunulmuştur.

Bu aşamadan sonra oluşturulan yapay sinir ağları eğitim işlemine tabi tutulmuştur. Test işlemleri için ayrı bir veri seti sunulmamış olup eğitim için sunulan verilerden %5'i test verisi olarak kullanılması için NeuroSolutions 4 programı ayarlanmıştır. Eğitim işlemleri tamamlanan yapay sinir ağlar veri üretim işlemi gerçekleştirilmiştir. Tüm yapay sinir ağı tipleri için aynı veri seti kullanılmıştır.

3. BÖLÜM

BULGULAR

Çalışmanın bu aşamasında eğitilen yapay sinir ağlarının birbirlerine göre karşılaştırma sonuçları ve bulgular verilecektir. Çalışma kapsamında 400 farklı tipte yapay sinir ağının eğitim işlemi yapılmıştır. Eşit koşulları sağlamak üzere aynı eğitim veri seti bütün ağların eğitiminde kullanılmıştır. Eğitim verilerinin %5 test için kullanılmıştır. Test verileri eğitim verileri içinden Nero Solution 4 programı tarafından seçilmiştir. Harici bir test verisi sunulmamıştır. YSA toplam maliyetlerinin diğer parti büyüklüğü yöntemleri ile karşılaştırılması bu bölümde verilecektir.

I. Ağ Çıktısı İle Arzu Edilen Çıktıların Karşılaştırması

Eğitilen her ağ için bir ağ numarası verilmiştir. Ağ numarası bazında hesaplanan korelasyon katsayıları, sipariş planları ve toplam maliyetten sapmaları Ek-4'de verilmiştir.

Hata kareler ortalamasının büyüklüğü (mean square error-MSE) ağın çıktıları ile arzu edilen çıktıların uyumun nasıl olduğunu belirlemek için kullanılabilir ancak iki datanın aynı doğrultuda hareket ettiğini yansıtmaz. Ağ çıktısı "x" ile arzu edilen çıktı "d" arasındaki korelasyon katsayısının formül 4.1 de tanımlandığı gibidir [37].

$$r = \frac{\frac{\sum_i (x_i - \bar{x})(d_i - \bar{d})}{N}}{\sqrt{\frac{\sum_i (d_i - \bar{d})^2}{N}} \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{N}}} \qquad 4.1$$

Korelasyon katsayısı -1 ile 1 aralığında değişir. “r=1” ise ağ çıktıları (x) ile ve arzu edilen çıktılar (d) arasında mükemmel pozitif doğrusal ilişki vardır. Şayet “r=-1” ise ağ çıktıları (x) ile ve arzu edilen çıktılar (d) arasında mükemmel negatif doğrusal ilişki vardır. Bu durumda ilişki ters yönde hareket etmektedir denebilir. Yani ağ çıktısı (x) artarken arzu edilen çıktı (d) azalmaktadır denir. “r=0” ise ağ çıktısı ile arzu edilen girdiler arasında herhangi bir ilişki yoktur denebilir. Ortadaki değerlerde ise kısmi ilişki vardır denebilir. Örneğin korelasyon katsayısının 0,88 olmasının anlamı ağ çıktılarının arzu edilen çıktılara oldukça uyduğudur [37].

Bu tez çalışmasında Nero Solution 4 programının sunmuş olduğu korelasyon katsayısı değer kullanılmıştır. Ayrıca korelasyon katsayısına göre “r” en iyi performansı gösteren ilk 10 ağ Tablo 3.1’de sunulmuştur.

Tablo 3.1. “r” korelasyon katsayısına göre en iyi performansı gösteren ilk 10 YSA

Sıra Numarası	Ağ Numaraları	"r" Korelasyon Katsayısı	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
1	12	0,98936	ÇKA	DeltaBarDelta	TanhAxon
2	11	0,98791	ÇKA	QuickProp	TanhAxon
3	9	0,98700	ÇKA	Step	TanhAxon
4	1	0,98569	ÇKA	Momentum	TanhAxon
5	19	0,95745	ÇKA	QuickProp	Linear TanhAxon
6	3	0,95251	ÇKA	Momentum	Linear TanhAxon
7	10	0,94554	ÇKA	ConjugateGradiant	TanhAxon
8	20	0,94463	ÇKA	DeltaBarDelta	Linear TanhAxon
9	18	0,93128	ÇKA	ConjugateGradiant	Linear TanhAxon
10	14	0,92259	ÇKA	ConjugateGradiant	Sigmoid Axon

Tablo 3.1’den anlaşılabileceği üzere yapay sinir ağı modeli çıktıları ile arzu edilen çıktılar birbirlerine uyumları çok iyidir.

Arzu edilen çıktılar ile yapay sinir ağı çıktısı arasında 0,8’den daha yüksek doğrusal ilişki olan ağların listesi korelasyon katsayına göre sıralı olarak Ek-5’de sunulmuştur. Buna göre 39 ağın çıktıları ile arzu edilen çıktılar arasındaki ilişki pozitif yönlüdür. 39 ağdan 19’u çok katmanlı yapay sinir ağı, 8 tanesi Radyal

tabanlı yapay sinir ağı, 12 tanesi ise kendinden öğrenmeli yapay sinir ağıdır. 0,8 den yüksek "r" değerine sahip YSA tipine göre dağılımı Şekil 3.1 de, öğrenme kuralına göre dağılımı Şekil 3.2'de, transfer fonksiyonuna göre dağılımı ise Şekil 3.3'te sunulmuştur.

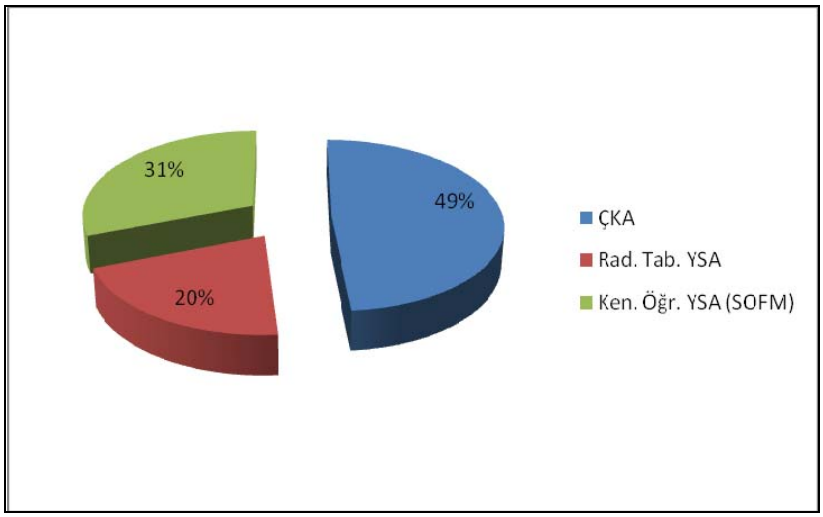

Şekil 3.1. "r" değeri 0,8 den daha yüksek ağların YSA tiplerinin dağılımı

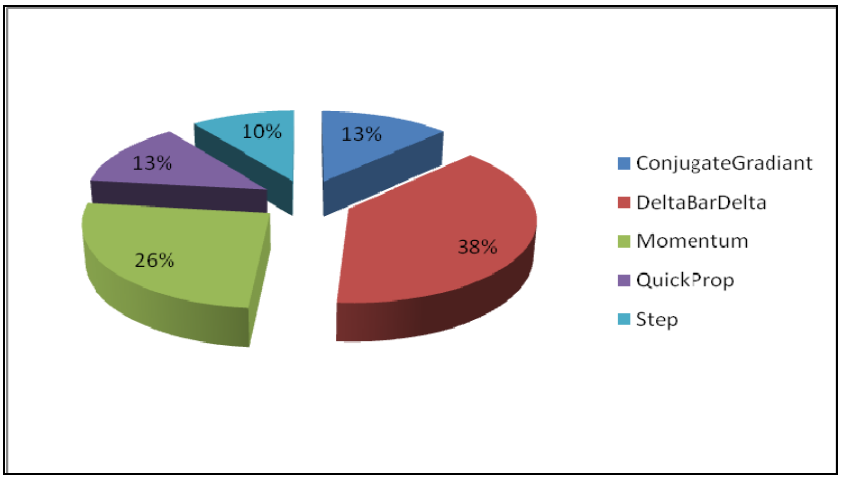

Şekil 3.2. "r" değeri 0,8 den daha yüksek ağların öğrenme kurallarının dağılımı

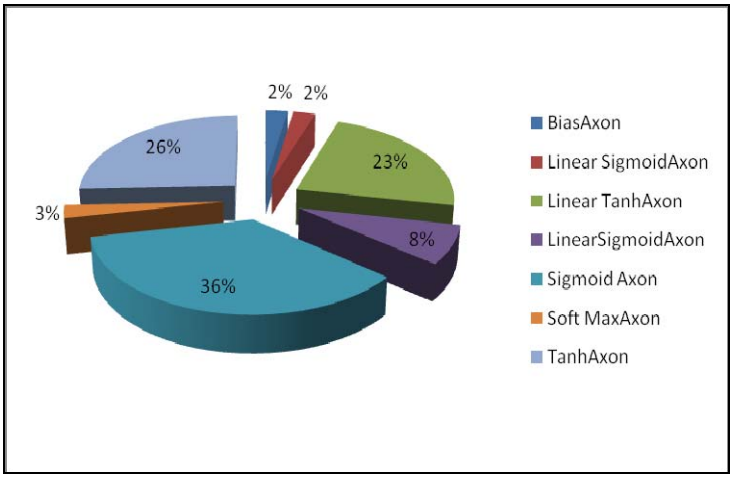

Şekil 3.3. "r" değeri 0,8 den daha yüksek ağların transfer fonksiyonu dağılımı

II. Optimum Sipariş Planına Göre Karşılaştırma

Yapay sinir ağlarının eğitim ve test işlemler NeuroSolutions 4 programında gerçekleştirilmiştir. Her ne kadar bu eğitim platformu öğrenme korelasyon katsayısana göre karşılaştırma imkanı verse de eğitimli yapay sinir ağlarının gerçek hayatta nasıl tahminlerde bulunacağının değerlendirilmesi gerekmektedir. Bu amaçla eldeki verilerden bir kısmı veri üretimi yapılmıştır.

Bu karşılaştırma kuralında kullanılan değerin hesaplama yöntemi Tablo 3.2, 4.3, 4.4. ve 4.5 de sırası ile gösterilmektedir. Buna göre;

Adım 1: Yılın ilgili döneminde sipariş var ise plan 1 yok ise 0 değeri atanır.

Tablo 3.2. WW sipariş planı

	Sipariş Planına Dönüştürülmüş WW Siparişleri											
Dönem	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**
Plan	**1**	**1**	**0**	**1**	**1**	**0**	**1**	**0**	**0**	**1**	**0**	**0**

Adım 2: Yapay sinir ağlarının sipariş planı ise üretim sonucunda elde değer için şayet ilgili dönemdeki 0,5 den büyük ise 1 küçük ise 0 değeri atanır.

Tablo 3.3. Yapay sinir ağları sipariş planı

	Sipariş Planına Dönüştürülmüş YSA Siparişleri											
Dönem	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**
Plan	**1**	**1**	**1**	**0**	**1**	**0**	**1**	**0**	**1**	**0**	**0**	**0**

Adım 3: Tablo 3.3 ve Tablo 3.2 de aynı dönemde yer alan plan değerleri eşit ise Tablo 3.4'de aynı döneme 1 farklı ise 0 atanır.

Tablo 3.4. Sipariş planı için 0,1 atama kriteri

	Şayet aynı dönemdeki değer WW=YSA ise 1 değil ise 0)											
Dönem	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**
Plan	**1**	**1**	**0**	**0**	**1**	**1**	**1**	**1**	**0**	**0**	**1**	**1**

Adım 4: Sipariş planın doğruluk yüzdesini öğrenmek için Tablo 3.4' deki değerler toplanarak tablo 5 deki $\sum$ sütununda yer alan değerler bulunur, toplamlar 12'ye bölünüp ve yüzle çarpılarak Tablo 3.5'deki %'de sütunundaki değerler bulunur.

$$\text{Sipariş Planı } \% = \frac{(1+1+0+0+1+1+1+1+0+0+1+1)}{12} x100 \qquad 4.2$$

Adım 5: Bu tez çalışmasında veri üretim işlemlerinde 123 setlik veri kullanıldığından bütün her bir ağ tipinde 123 adet farklı girdi için 123 farklı plan oluşturulmaktadır. Tablo 3.5 de % sütununda yer alan veriler toplanıp 123 ile bölünmesi ile bu karşılaştırma kriteri değerine ulaşılmaktadır.

Tablo 3.5 YSA tipleri için sipariş planlarının oluşturtması

Dönem	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**	$\sum$	%
Örn. Veri Grubu1	1	1	0	0	1	1	1	1	0	0	1	1	8	0,6666667
Örn. Veri Grubu2	1	1	1	1	1	1	1	1	1	0	1	1	11	0,9166667
Örn. Veri Grubu3	1	1	1	1	1	1	1	1	0	0	1	1	10	0,8333333
Örn. Veri Grubu4	1	0	1	1	1	1	1	1	1	1	1	0	10	0,8333333
Örn. Veri Grubu5	1	1	1	1	1	1	1	1	0	1	0	1	10	0,8333333
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
Örn. Veri Grubu123	1	1	1	1	0	1	1	1	0	0	1	0	8	0,6666667

Bu karşılaştırma işleminde yarışma diğer parti büyüklüğü yöntemleri de katılmıştır. Diğer parti büyüklüğü belirleme metotları için yukarıda süreç uygulanarak karşılaştırmada kullanılmak üzere hesaplama yapılmıştır. Sipariş planına göre en iyi performansı gösteren ilk 10 parti büyüklüğü/yapay sinir ağı yöntemi Tablo 3.6'da sunulmuştur.

Tablo 3.6. Sipariş planına göre en iyi performansı gösteren ilk 10 yöntem.

Sıra Numarası	Ağ Numaraları	Sipariş Planı Yüzdesi	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
1	190	91,60256	RBN	DeltaBarDelta	Sigmoid Axon
2	240	91,47436	RBN	DeltaBarDelta	TanhAxon
3	220	91,41026	RBN	DeltaBarDelta	Linear TanhAxon
4	164	91,15385	RBN	QuickProp	Axon
5	165	91,15385	RBN	DeltaBarDelta	Axon
6	26	91,08974	ÇKA	ConjugateGradiant	BiasAxon
7	30	91,08974	ÇKA	ConjugateGradiant	LinearAxon
8	31	91,08974	ÇKA	QuickProp	LinearAxon
9	32	91,08974	ÇKA	DeltaBarDelta	LinearAxon
10	241	91,08974	RBN	Momentum	Axon

150 adet parti büyüklüğü belirleme yönteminin (yapay sinir ağları ve diğer parti büyüklüğü belirleme yöntemleri dahil) sipariş planına göre %80 üzerinde başarı göstermiştir. Diğer parti büyüklüğü metotlarının genel sırlamadaki durumu ise Tablo 3.7'de sunulmuştur.

Tablo 3.7. Diğer parti büyüklüğü metotlarının sipariş planı yüzdesi ve sıralama dereceleri

Sıralama	Yöntem	Sipariş Planı Yüzdesi
4	Silver Meal	91,21795
152	Ekenomik Sipariş Büyüklüğü Yöntemi	79,74359
191	Parçalı Dönem Dengesi Yöntemi	71,47436
236	En Düşük Toplam Maliyet Yöntemi	63,78205
288	En Düşük Birim Maliyet Yöntemi	55,00000

Sipariş planı karşılaştırma kriterlerine göre 0,8 den yüksek başarı gösteren yapay sinir ağlarının YSA tipine göre dağılım grafiği Şekil 3.4'te, öğrenme kuralına göre dağılım grafiği Şekil 3.5'te, transfer fonksiyonuna göre dağılım grafiği Şekil 3.6'da sunulmuştur. Bu kriter Lotffi K.Gaafarve arkadaşlarının [5] ve Radzi ve arkadaşları [13] tarafından da kullanılmıştır.

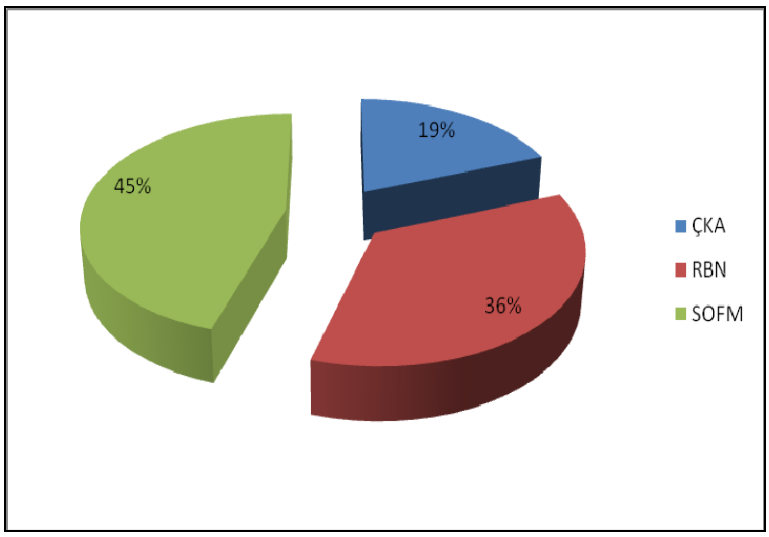

Şekil 3.4. Sipariş planında %80 den daha yüksek başarı gösteren yapay sinir ağların YSA tipine göre dağılımı

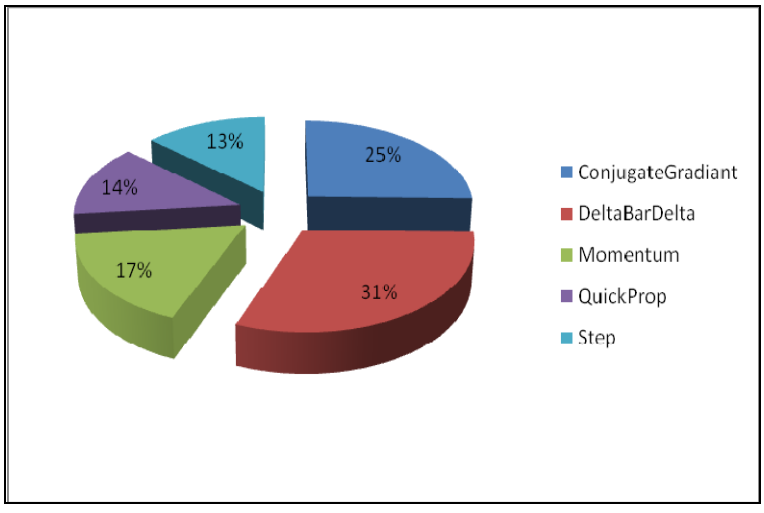

Şekil 3.5 Sipariş planında %80 den daha yüksek başarı gösteren öğrenme kuralına göre dağılımı

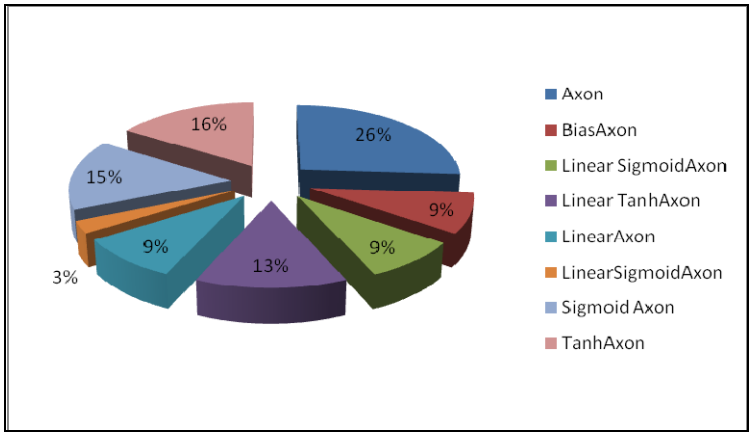

Şekil 3.6 Sipariş planında %80 den daha yüksek başarı gösteren ağların transfer fonksiyonlarına göre dağılımı

III. Optimum Maliyetten Sapma Kriterine Göre Karşılaştırma

Arzu edilen verilerin elde edilmesi amacı ile eldeki talep bilgileri WW yöntemi ile WinQSB programı kullanılarak çözülmüştür ve sipariş büyüklükleri elde edilmiştir Yapay sinir ağlarının eğitiminde ise Tablo 3.8 de "1,0" WW sipariş planları kullanılmıştır. Yapay sinir ağlarının eğitimin müteakibinde yapay sinir ağı sipariş planı oluşturulması için aşağıdaki üç işlem adımı takip edilir.

Adım 1: Yılın ilgili döneminde sipariş var ise plan 1 yok ise 0 değeri atanır.

Tablo 3.8. WW sipariş planı

	Sipariş Planına Dönüştürülmüş WW Siparişleri											
Dönem	1	2	3	4	5	6	7	8	9	10	11	12
Plan	1	1	0	1	1	0	1	0	0	1	0	0

Adım 2: Yapay sinir ağlarının sipariş planı ise üretim sonucunda elde değer için şayet ilgili dönemdeki 0,5 den büyük ise 1 küçük ise 0 değeri atanır.

Tablo 3.9. Yapay sinir ağları sipariş planı

	Sipariş Planına Dönüştürülmüş YSA Siparişleri											
Dönem	1	2	3	4	5	6	7	8	9	10	11	12
Plan	1	1	1	0	1	0	1	0	1	0	0	0

Adım 3: Tablo 3.8 ve Tablo 3.8 de aynı dönemde yer alan plan değerleri eşit ise Tablo 3.10'de aynı döneme 1 farklı ise 0 atanır. Her bir ağ tipi için 123 setlik veri kümesinin her bir veri grubuna bu işlem uygulanır.

Tablo 3.10. Sipariş planı için 0,1 atama kriteri

	Şayet aynı dönemdeki değer WW=YSA ise 1 değil ise 0)											
Dönem	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**
Plan	**1**	**1**	**0**	**0**	**1**	**1**	**1**	**1**	**0**	**0**	**1**	**1**

Adım 4: Elde edilen sipariş planı Decision Analysis V1,42 kullanılarak her bir ağ tipinin toplam maliyetleri bulunmuştur.

Tablo 3.11. Yapay Sinir ağları toplam maliyet hesaplanması

Dönem	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**	$\sum$ TM
Örn. Veri Grubu1	1	1	0	0	1	1	1	1	0	0	1	1	27154 TL
Örn. Veri Grubu2	1	1	1	1	1	1	1	1	1	0	1	1	26500 TL
Örn. Veri Grubu3	1	1	1	1	1	1	1	1	0	0	1	1	29984 TL
Örn. Veri Grubu4	1	0	1	1	1	1	1	1	1	1	1	0	38767 TL
Örn. Veri Grubu5	1	1	1	1	1	1	1	1	0	1	0	1	27154 TL
.	.	.	.	.	.	.	.	.	.	.	.	.	.	
.	.	.	.	.	.	.	.	.	.	.	.	.	.	
Örn. Veri Grubu123	1	1	1	1	0	1	1	1	0	0	1	0	72905 TL

Yapay sinir ağları ile optimal çözüm toplam maliyet karşılaştırması ise maliyetler arasındaki sapma esas alınarak aşağıdaki formüle göre karşılaştırma yapılmıştır.

TM_{WW} :Optimal çözüm (Wagner-Whitin) siparişlerinin toplam maliyeti

TM_{YSA} :Yapay sinir ağı siparişlerinin toplam maliyeti.

TM_{Sapma} : Optimum maliyetten sapma yüzdesi.

$$TM_{Sapma} = [(\sum_{i=1}^{130} \frac{TM_{YSA_i} - TM_{WW_i}}{TM_{WW_i}}) / 123] x100 \qquad 4.3$$

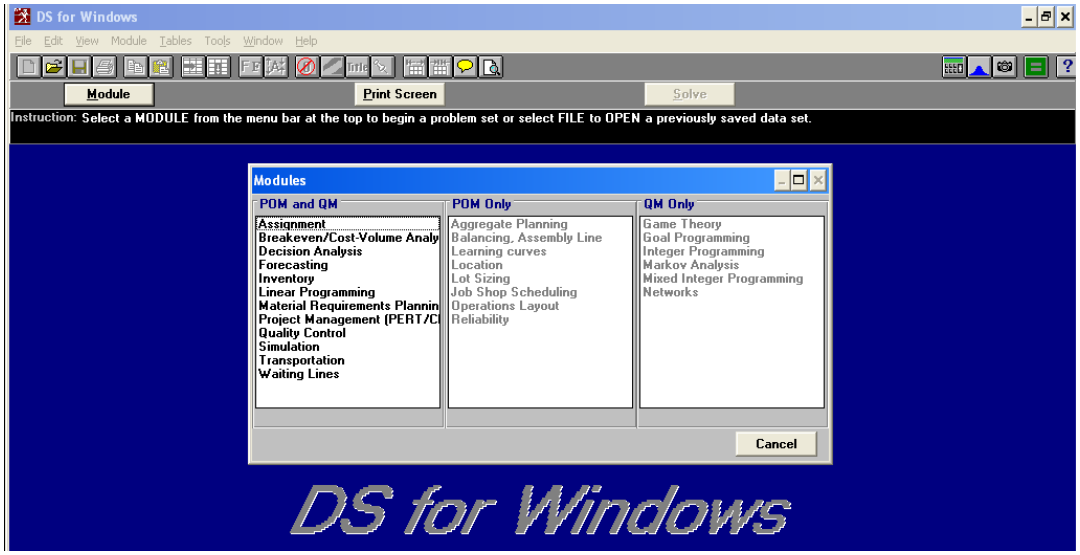

Şekil 3.7. Decision Analysis V1,42 programının ekran görüntüsü

Tablo 3.12. Wagner-Whitin optimum maliyetinden en az sapma gösteren ilk 10 yöntem.

Sıra Numarası	Ağ Numaraları	WW Toplam Maliyetten Sapma Yüzdesi	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
1	220	0,129894	RBN	DeltaBarDelta	Linear TanhAxon
2	180	0,147287	RBN	DeltaBarDelta	Linear TanhAxon
3	190	0,150026	RBN	DeltaBarDelta	Sigmoid Axon
4	200	0,197210	RBN	DeltaBarDelta	TanhAxon
5	202	0,201596	RBN	Step	Axon
6	130	0,203873	SOFM	DeltaBarDelta	Sigmoid Axon
7	128	0,205060	SOFM	ConjugateGradiant	Sigmoid Axon
8	177	0,210865	RBN	Momentum	Linear TanhAxon
9	240	0,210974	RBN	DeltaBarDelta	TanhAxon
10	15	0,212258	ÇKA	QuickProp	Sigmoid Axon

Optimum maliyetlerden sapma karşılaştırmasına diğer parti büyüklüğü yöntemleride dahil edilmiştir. Ancak diğer parti büyüklüğü yöntemleri WinWSB programı kullanılarak çözülmüş ve toplam maliyetleri bulunmuştur. Wagner Whitin toplam maliyetinden en az sapmayı başaran parti büyüklüğü belirleme yöntemler Tablo 3.12 de arz edilmiştir. Burada dikkat edilmesi gerek husus ise 220 numaralı Radyal tabanlı yapay sinir ağı toplam maliyetleri Silver Meal yönteminden daha iyi performans göstermesidir.

43 adet yapay sinir ağı parti büyüklüğü belirleme yönteminin (yapay sinir ağları ve diğer parti büyüklüğü belirleme yöntemleri dahil) Wagner Whitin toplam maliyetinden %0,25 den daha az sapma göstermişlerdir. Diğer parti büyüklüğü yöntemlerinin karşılaştırma dereceleri Tablo 3.13 de sunulmuştur. Bu kriter Lotffi K.Gaafarve arkadaşlarının [5] ve Aarts ve arkadaşları [10] tarafından da kullanılmıştır.

Tablo 3.13. Parti büyüklüğü yöntemlerinin Wagner Whitin toplam maliyetinden sapma yüzdeleri ve sıralama dereceleri

Sıralama	Yöntem	WW yöntemi maliyetinden Sapma Yüzdeleri
2	Silver Meal	0,13215
191	Parçalı Dönem Dengesi Yöntemi	1,37116
236	En Düşük Toplam Maliyet Yöntemi	1,62001
288	En Düşük Birim Maliyet Yöntemi	3,11625
152	Ekenomik Sipariş Büyüklüğü Yöntemi	6,41407

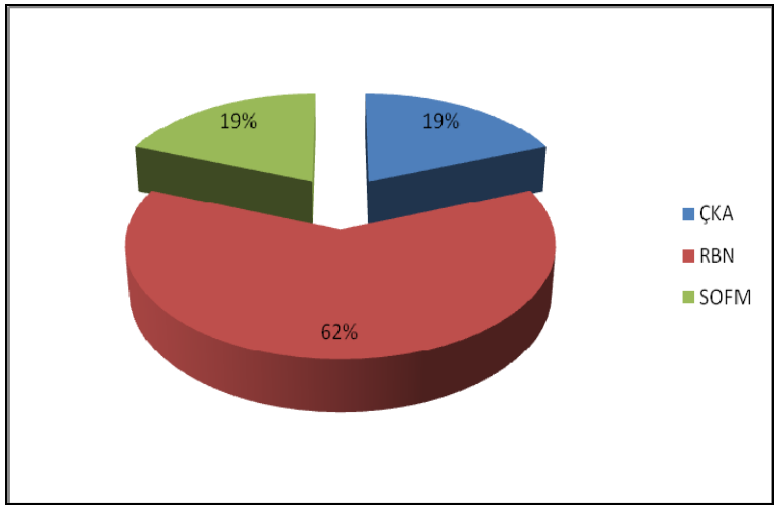

Şekil 3.8 WW yöntemi maliyetinden % 0,25 den daha sapan az ağların YSA tipine göre dağılımı

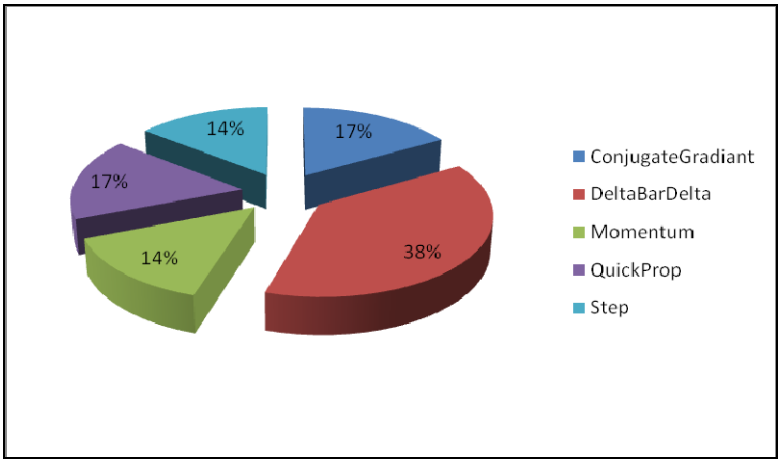

Şekil 3.9 WW yöntemi maliyetinden % 0,25 den daha az sapan ağların öğrenme kuralına göre dağılımı

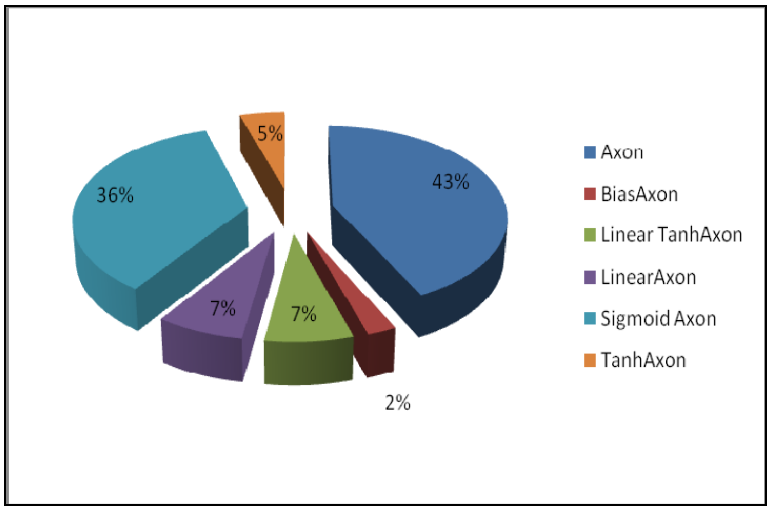

Şekil 3.10 WW yöntemi maliyetinden % 0,25 den daha az sapan ağların transfer fonksiyonuna göre dağılımı

Yapılan bu karşılaştırmalar neticesinde 220 numaralı ağın özellikle Wagner Whitin toplam maliyetinden en sapma gösteren ağ olduğu belirlenmiştir. Bu durum Tablo 3.12 de görülebilecektir. Tablo 3.13 de görülebileceği toplam maliyet karşılaştırma kriterinde en iyi ikinci performansı Silver Meal algoritması göstermiştir. Yine 220 numaralı yapay sinir ağı Tablo 3.8 den anlaşılacağı üzerede sipariş planı karşılaştırma kriterine göre Silver Meal yönteminden daha iyi sonuç göstermiştir. Bu aşamadan sonra 220 numaralı Radyal tabanlı yapay sinir ağı topolojisi "yapay sinir ağı tabanlı metot" (YSATM) olarak adlandırılmıştır. YSATM'nin ve diğer parti büyüklüğü metotlarının

karşılaştırmaları Tablo 3.14 sunulduğu gibidir. Tablo 3.14'de Wagner-Whitin toplam maliyeti sapma yüzdesi ve isabetli sipariş planı yüzdesine göre karşılaştırma yapılmıştır. Yüzde değerleri % sütununda sunulmuştur. Derece sütununda ise 400 adet yapay sinir ağı ile 5 tip parti büyüklüğü yönteminin başarısına göre durumunda sıralama derecesidir.

Tablo 3.14. Optimum çözüme göre başarı yüzdeleri

	EOQ		LTC		LUC		PPB		SM		YSATM	
	%	Derece	%	Derece	%	Derece	%	Derece	%	Derece	%	Derece
WW Toplam Maliyetinden Sapma	6,414	331	1,620	169	3,116	247	1,371	162	0,132	2	0,130	1
İsabetli Sipariş Planı	79,744	152	63,782	236	55,000	288	71,474	191	91,218	4	91,410	3

YSATM Radyal tabanlı yapay sinir ağıdır. Ağ topolojisinde 1 adet girdi katmanı, 1 adet gizli katman ve 1 adet çıktı katmanı kullanılmıştır. Girdi katmanın 15 adet düğüm noktası kullanılmıştır. Bu düğüm noktaları; 12 tanesi 12 dönemlik talebi, 1 tanesi elde bulundurma maliyeti, 1 tanesi hazırlık maliyeti, 1 tanesi sipariş verme maliyetini temsil etmektedir. Gizli katmanda ise 30 adet düğüm noktası kullanılmıştır. Ağ ağırlıklarının güncellemesinde geri yayılım algoritması kullanılmıştır.. Karşılaştırma kuralı olarak StandartFulll kullanılmıştır. Bu yöntem karşılaştırmalı bir öğrenme kuralı olup her düğüm noktasında kazan tek bir ağırlık ağın sonraki aşamasına geçebilmektedir. Metrik Dot Product kullanılmıştır. Yani sinir hücresine girdi ile çıktı arasındaki mesafeyi çıktı vektörü (y) fonksiyonu formül 4.4 'de sunulmuştur.

$$y_i = \sum_j x_j w_{ij} \qquad 4.4$$

YSATM'nin gizli katmanındaki öğrenme kuralı DeltaBarDelta'dır. Bu öğrenme kuralı değişen durumlara uydurulabilinen öğrenme kuralıdır. Momentum ve adım büyüklüğü önceki hatanın değerine göre güncellenir. YSATM'nin transfer fonksiyonu olarak LinearTanhAxon kullanılmış olup formül 4.5 de ifadesi sunulmuştur.

$$f(x_i, w_i) = \begin{bmatrix} -1 & x_i^{lin} < -1 \\ 1 & x_i^{lin} > 1 \\ x_i^{lin} & diğer \end{bmatrix} \quad 4.5$$

Çıktı katmanında 12 adet düğüm noktası kullanılmıştır. Çıktı katmanında gizli katman ile aynı transfer fonksiyonu ve öğrenme kuralı kullanılmıştır. Öğretmensiz öğrenmene için 1000 takrar, öğretmenli kısmı için 10000 tekrar yaptırılmıştır. YSATM'nin topolojisi Şekil 3.10'da sunulmuştur.

x_i :Girdiler
S_c :Hazırlık Maliyeti
H_c :Elde bulundurma maliyeti
V_c :Değişken maliyetler
W_i :Ağılıklar
O_i :Çıktılar

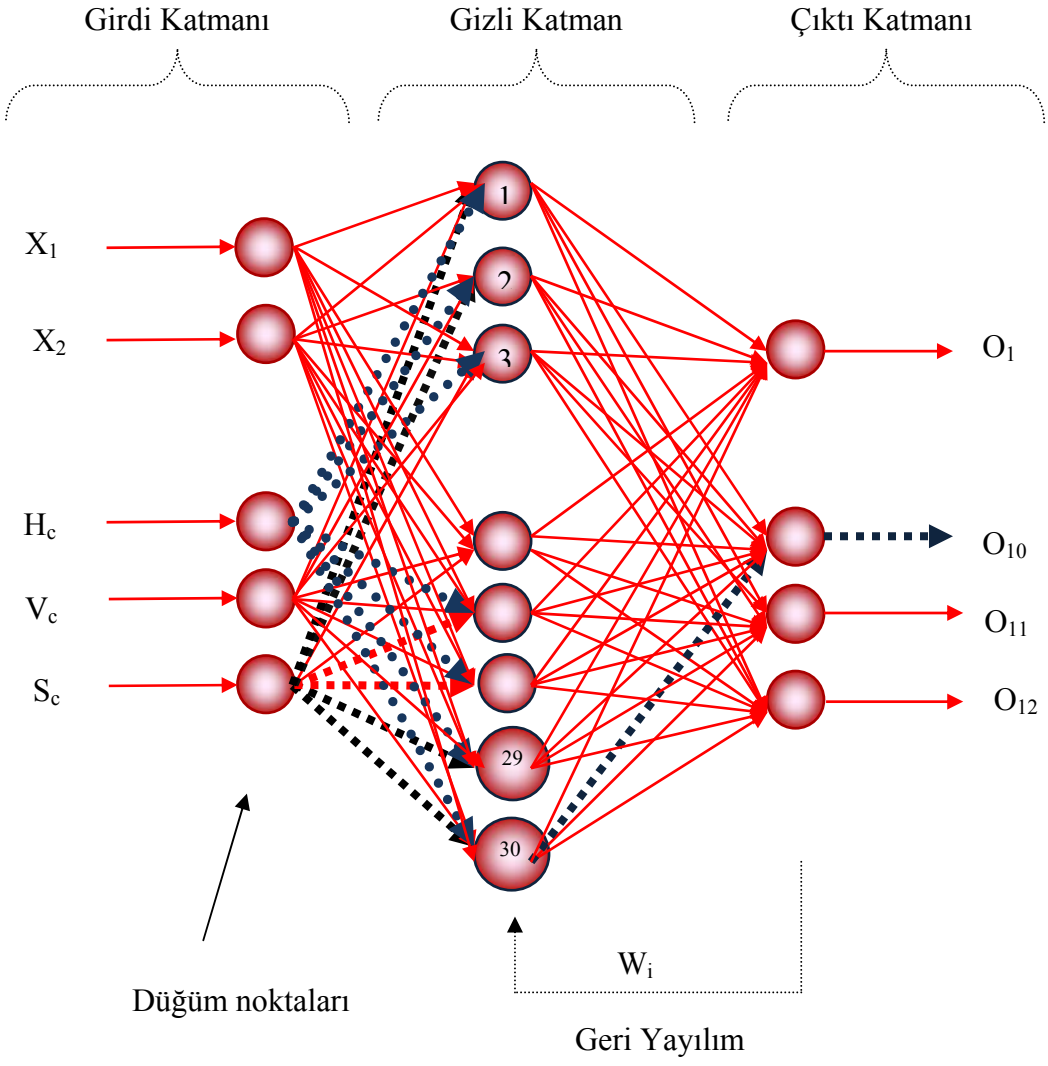

Şekil 3.11 YSATM topolojisi

4. BÖLÜM

TARTIŞMA-SONUÇ VE ÖNERİLER

Yapay sinir ağlarının uygulama alanı giderek artmıştır. 1970 yılından sonra yaşanan suskunluğun aksine pek çok alanda kullanılmaya başlanmıştır. Yapay sinir ağları esnek oluşu karmaşık problemleri çözmedeki yeteneği sayesinde kullanımın giderekte artacaktır. Günümüzde uçak teknolojisinden, uzay araçları teknolojisine, radar sistemlerinde, hasta tanı ve teşhis sistemlerinde kullanılmaya başlanmaktadır. Yapay sinir ağlarının kullanılmak istenmesinin asıl nedeni; bilgisayar işlem gücü kapasitesinin insan tecrübesi ve insan beyninin yeni durumlara karşı adaptasyon olmasındaki esnekliğinin tek bir ortamda birleştirilmesinin büyük avantajlarıdır.

Bu tez çalışmasında X işletmesinin son 5 yıla ait 186 farklı malzeme kalemine ait veriler elektronik ortamda alınmıştır. Yapılan düzenlemeler esnasında 7 dönemlik veri X işletmesinin kaynak planlama programı kaynaklı hata nedeniyle uyuşmazlık olduğu tespit edildiğinden söz konusu veriler tez çalışması kapsamından çıkarılmıştır. Veriler düzenlendikten sonra optimum parti büyüklüklerinin bulunması amacı ile WinQSB programı kullanılarak Wagner-Whitin yöntemi ile çözülmüştür. Daha sonra yapay sinir ağlarının birbirleri ile ve diğer parti büyüklüğü yöntemleri ile karşılaştırılmasında kullanılmak üzere hangi verilerden faydalanılacağını belirlemek üzere AHP yöntemi kullanılmıştır. AHP yöntemi sonucunda 123 dönemlik veri içeren veri setinin seçimi yapılmıştır. Bu işlemden sonra geriye kalan 800 veri ile yapay sinir ağlarının eğitim ve test işlemleri gerçekleştirilmiştir. Test işlemlerinde çapraz doğrulama (cross-validation) yöntemi kullanılmıştır. Yapay sinir ağlarının eğitiminde çeşitli tiplerde oluşturulan toplam 400 farklı ağ yapısı kullanılmıştır. Her bir farklı ağ yapısı numaralandırılmış ve karşılaştırmalarda kullanılmak üzere veri üretimi gerçekleştirilmiştir. Bu işlemden sonra

her bir ağ yapısı için NeroSolution 4 programının vermiş olduğu "r" korelasyon katsayısı, optimum sipariş planı ve optimum maliyetten sapma kriterlerine göre karşılaştırma yapılmıştır. 220 numaralı optimum maliyetten sapma ve optimum sipariş planın karşılaştırma kriterlerinin her ikisinde SM yönteminden daha iyi performans göstermiştir. Bu nedenle 220 numaralı yapay sinir ağı tabanlı parti büyüklüğü belirleme metodu (YSATM) olarak seçilmiştir.

Söz konusu uygulama alanlarından birisi ise parti büyüklüğünü belirleme problemleridir. Daha önceki çalışmalar göstermiştir ki yapay sinir ağları ile geliştirecek olan algoritmaların bu problemi çözeme kapasitesi vardır. Hatta bazı çalışmalarda % 80 üzerinde öğrenme yüzdesi sağlanmıştır.

- Lotffi K.Gaafar ve arkadaşları çalışmalarının sonucunda yapay sinir ağlarının parti büyüklüğü belirleme probleminde gürbüz performans gösterdiği ispatlanmıştır. Bu tez çalışmasında yapılan ilk karşılaştırma kriterinde yapay sinir ağlarını tanıtılan girdiler ile çıktılar arasında pozitif doğrusal bir ilişki tespit edilmiştir. Bu ilişkinin büyüklüğü ve şiddeti seçilen ağ tipine, öğrenme kuralına ve transfer fonksiyonuna göre değişmektedir. Yapılan deneylerde bu tez çalışmasında kullanılan veriler için en iyi korelasyon katsayısına çok katmanlı yapay sinir ağları sahip olmuştur. Ancak transfer fonksiyonu ve öğrenme kuralı değişiklik arz etmektedir.
- Lotffi K.Gaafar ve arkadaşları iki farklı dönemsel yapıya göre değerlendirmişlerdir. Mevsimsel talep desenlerinde ani değişimler olduğu durumlar için yapay sinir ağlarının diğer parti büyüklüğü yöntemlerinden daha iyi performans verdiği belirtilmiştir. Deneyler sonucunda elde edilen veriler bu bulguyu desteklemektedir. Bu tez çalışmasına gerçek veriler kullanılmış olup talep bilgileri 186 kalem farklı kalem malzeme grubuna aittir. Uygulamanın yapıldığı X işletmesi sipariş üzerine çalıştığında taleplerde piyasa koşullarına bağlı olarak ani iniş ve çıkışlar olabilmektedir. Yapılan karşılaştırmalarda eğitimi yapılan farklı yapay sinir ağı tiplerinin üçte biri Siver Meal haricindeki diğer parti büyüklüğü metotlarından daha iyi performans göstermiştir. Bu durum yapay sinir ağlarının karşılaştırıldığı her iki karşılaştırma tipi (toplam maliyetten sapma yüzdesi ve sipariş planlarındaki isabet yüzdesi) için de geçerlidir.

- Lotffi K.Gaafar ve arkadaşlarının çalışmasında yapay sinir ağlarının sunulan maliyet girdisi etkileşimde olduğu bildirilmiştir. Yapılan analizde maliyet etkileşiminin geniş bir hata terimi tarafından gölgelendiği bildirilmiştir. Parti büyüklüğü metotları arasında sabit sipariş miktarının en kötü performans gösterdiği bildirilmiştir. Bu tez çalışmasında karşılaştırmaya dahil edilen 5 tip parti büyüklüğü yöntemi arasında ise isabetli sipariş planı yüzdesinde en kötü performansı en düşük toplam maliyet (LTC) göstermiştir. Wagner-Whitin toplam maliyetlerinden sapma yüzdelerine göre yapılan karşılaştırmada ise en kötü performansı ekonomik sipariş miktarı yöntemi vermiştir.

Bu tez çalışması çerçevesinde gerçekleştirilen deneyler sonucunda yapılan karşılaştırmalar sonucunda aşağıdaki yargılara varılabilir.

- Gerçekleştirilen deneyler esnasında yapay sinir ağlarının eğitimi sonrası elde edilen çıktılar ile arzu edilen çıktılar arasında yüksek derecede ilişki belirlenmiştir. Arzu edilen çıktılar ile yapay sinir ağlarından elde edilen veriler arasında %80'den yüksek 39 farklı ağ tipi belirlenmiştir. Bu 39 ağ tipinin % 49 çok katmanlı yapay sinir ağı, %31'i kendinden öğrenmeli YSA, %20'si ise radyal tabanlı yapay sinir ağıdır. En yaygın öğrenme kuralı DeltaBarDelta öğrenme kuralıdır. En yaygın transfer fonksiyonu %36 ile SigmoidAxon transfer fonksiyonu gerçekleştirmiştir.

- Sipariş planlarına göre yapılan karşılaştırmalarda en iyi performans gösteren ilk 10 ağın 6 tanesi radyal tabanlı yapay sinir ağıdır. Optimum sipariş planına %80 isabet gösteren yapay sinir ağı 150 adettir. Optimum sipariş planına göre % 80 üzerinde performans gösteren ağların %45'i kendinden öğrenmeli yapay sinir ağı, %36 radyal tabanlı yapay sinir ağı, % 19'u ise çok katmanlı yapay sinir ağıdır. Yine bu ağlar içinde en yaygın öğrenme kuralı %31 ile DeltaBarDelta olmuştur. En yaygın transfer fonksiyonu ise Axon transfer fonksiyonu olmuştur.

- Wagner-Whitin toplam maliyetinden sapma karşılaştırmasında ise en başarılı ilk 10 ağın 7'si radyal tabanlı yapay sinir ağı olmuştur. Söz konusu 7 adet radyal tabanlı yapay sinir ağın 5'i DeltaBarDelta öğrenme kuralı olmuştur. Wagner-

Whitin toplam maliyetlerinden %0,25'den daha az sapma gösteren yapay sinir ağları toplam 43 adet olmuştur. Söz konusu bu ağlardaki en yaygın olanı %62 radyal tabalı yapay sinir ağı olmuştur. Kendinden öğrenmeli ağlar %19, çok katmanlı ağların yaygınlığı ise yine %19 olmuştur. Bu ağlarda en yaygın öğrenme kuralı %38 ile DeltaBarDelta öğrenme kuralı olmuştur. En yaygın transfer fonksiyonu ise Axon transfer fonksiyonu olmuştur.

Bu sonuçlara göre toplam maliyet karşılaştırması ve sipariş planı karşılaştırmasında olduğu gibi en başarılı ağlar arasında en yaygını radyal tabanlı ağlar ve öğrenme kuralı olarak ise DeltaBarDelta öğrenme kuralı olmuştur.

Lotffi K.Gaafar çalışmasında optimum sipariş deseni üretilmesinde yapay sinir ağlarının başarı göstermesine rağmen, en iyi maliyet performansı yapay sinir ağını optimum maliyet ile eğiterek elde edilebileceğini belirtilmiştir. Çıktı katmanından sonra maliyetin çıktı katmanında tanımlanmış parti büyüklüğü belirlemenin fonksiyonu gibi hesaplandığı hesaplama katmanı ilave edilerek başarılabileceği belirtilmiştir. Bu tez çalışmasında ise optimum maliyetler yapay sinir ağlarına hiçbir şekilde tanıtılamamıştır. Yapay sinir ağlarının eğitiminde talep büyüklükleri kullanılmıştır. Optimum maliyet yerine girdi olarak elde bulundurma maliyeti, hazırlık maliyeti ve değişken maliyetler kullanılmıştır. Arzu edilen veriler olarak ise sipariş büyüklükleri yerine sipariş planları kullanılmıştır. Böylece yapay sinir ağlarının talebin büyüklüğünden siparişin olup olmayacağının belirlenmesi beklenmiştir. Sipariş planından parti büyüklükleri ve toplam maliyet hesaplanmıştır. Bu yöntem parti büyüklüğü yöntemine yapay sinir ağlarını uygulayan daha önce yapılmış önceki çalışmalardan daha iyi sonuç vermiştir.

Wagner-whitin yöntemi deterministik şartlar altında en uygun çözümü vermektedir. Ancak günümüz şartlarında üretim programları değişkenleri arz etmekte, her an yeni girdilerin sisteme dahil olması kaçınılmaz olmaktadır. Bu tez çalışması sipariş üzerine üretim yapan, faaliyet alanı geniş, talep büyüklüklerinin ani dalgalanmalara açık olduğu bir işletmeye ait gerçek veriler kullanılmıştır. Sonuç olarak parti büyüklüğü probleminin günümüzdeki değişimlerinin mevcut olduğu uygulama çalışması olmuştur. Yapay sinir ağları eğitim amacı ile sunulan

veriler parti büyüklüğü belirleme problemi açısından tüm gürültüleri içermektedir. Yapılan karşılaştırmalar sonucunda yapay sinir ağlarının bu gürültülerle baş edebildiği ve problemin sevk ve idaresini başarılı bir şekilde sağladığı söylenebilir. Pek çok farklı bilimsel alanda başarılı bir şekilde uygulanan yapay sinir ağları parti büyüklüğü problemine uygulanabilecektir.

Bu çalışmada sonraki çalışmalara kapsamında aşağıdaki iyileştirmeler yapılarak YSATM'nin performansı geliştirilebilir:

- Yapılan değerlendirilmeler sonucunda SM yönteminden daha iyi performans gösterebilen yapay sinir ağı topolojisi elde edilmiştir. Yapay sinir ağının performansının geliştirilmesine yönelik öğretmensiz öğrenme ve öğretmenli öğrenme tekrar sayıları artırılabilir. Ayrıca DelteBarDelta öğrenme kuralının adım büyüklüğü, ilave, çarpa ve düzeltici faktörler üzerine sistematik değişiklikler yapılarak ağın performansında iyileştirme sağlanabilir.
- Yapılan çalışma gerçek veriler kullanılarak yapılmıştır. Bu nedenle bu tez çalışması literatürde yer alan çalışmalardan ayrılmaktadır. Literatürde yer alan çalışmaların büyük çoğunla veri üretim işlemleri yapılarak sanal veriler üzerinde değerlendirmeler yapılabilir. Çalışmanın özgünlüğünü bozmadan farklı işletmelere ait gerçek veriler kullanılarak yapay sinir ağlarının eğitim ve testinde kullanılan veri seti genişletilebilir. Bu sayede YSATM'nin performansı geliştirilebilir.
- Sonraki çalışmalar aşamasında yapılabilecek diğer bir yöntem ise eğitim ve test işlemleri sonrasında elde edilen ağırlıklar genetik algoritma ve arı algoritması gibi diğer meta sezgisel algoritmalar kullanılarak YSATM'nin performansı geliştirilebilir.

EKLER

EK-1 Malzeme Listesi ve Malzeme Grupları

S/No	P.No	M.Adı	Malzeme Grubu	S/No	P.No	M.Adı	Malzeme Grubu
1	3.4001	ACTUATOR	3	94	6Y2A-439	STARTING MOTOR 24 V	3
2	72582	TURBINE WHEEL	2	95	6Y2A-450	SIGNAL,SWITCH	2
3	157686	RADIATOR	2	96	7749906-10	HEAD ASSY	3
4	183842	JUMBER BAR SUPPORT	3	97	7BL/410057	PUMP AXIAL PİST	6
5	241011	MAFSAL MODULAT.SLIP I	5	98	8.BL 3.5001	PISTON NTERNAL COM	6
6	282197	HOSE KIT	2	99	8.BL. P5	RİNG SET.PISTON	2
7	282198	HOSE KIT L.H.COMPT	2	100	8.BL/R2	CONNECTING ROD.PIST	3
8	282200	HOSE KIT	2	101	8P082	A ROCKER HOUSING	6
9	282201	HOSE KIT R.H.COMPT	3	102	AMS 4202	PLAKA	3
10	286117	CONTROL 2-WAY	3	103	AMS 5537	SHEET,METAL	5
11	288746	BEARING	3	104	AMS5536	THICK SHEET METAL	5
12	288753	BEARING	3	105	AMS-6350	PLATE,METAL	5
13	291020	VALVE	6	106	BL.160-23	GOVERNOR.DIESEL ENG	4
14	377573	RING,SNAP	3	107	BL:13	VALVE.POPPET.ENGINE	3
15	410058	BULB	3	108	BRE EM 1010 MN	PLENATARY GEAR	1
16	460047	ACTUATOR, E LECTRO-MA	3	109	C5952	VALVE EXHUST	3
17	1366010	MOTOR SUBASSY	2	110	D0704	ZYLINDERMITKOLBEN	3
18	3069759	INJECTOR ASSEMBLY	4	111	D1744	BEARING	3
19	3803626	KIT CYLINDER	2	112	D8046	ANAYATAKN06	2
20	5101483	BLOWER ASSEMBLY,DIE	4	113	E10-SHSB	COUPLING ASSY	3
21	5102117	TURBOCHARGER ASSEMB	4	114	ESTERI D 240	PUMP	6
22	5106223	SEAL PLAIN	3	115	ESTERI PK PU	FOAM METER	3
23	5106329	SEAL	2	116	FOR 9 340 210 070-S-A	SWITCH	3
24	23511176	TRANSMITTER,PRESS UR	4	117	FOR 9 340 310 040-S	LIMIT SWITCH	3
25	100540102	LEG-RIG	3	118	HERION 2625600.0150	MAGNETIC VALVE TANK	6
26	100560102	GRENADE POUCH	1	119	HOF 345 420 055 TYPE 24	DIAPHRAM CYLINDER	6
27	100630202	MEDICAL POUCH	1	120	HYB 114 0631	SELENOD VALVE	3
28	306480002	MONITOR LIGHT	3	121	KPT06A168SX	CONNECTOR	3
29	1730003002189	ARM,CENTER STEERING	2	122	MS17926-14	RUBBER PAD	3
30	2530011115156	ARM,STEERING GEAR	2	123	OEM AUT NPT 1/8 7042-4	PRESSURE SWITCH LI.	6
31	4710009174784	TUBE,METALLIC	5	124	OMV 2153-1	PINION	2
32	4920007062061	CONNECTOR AND CABLE	5	125	OMV SK-357-4	HYDR.CYLINDER	6
33	07.020.01.00	BOOSTER POMP	4	126	PAGE:3-745	DICHTUNGRADIAL	3
34	0MV 2108-26	TENSION SPRING	3	127	PC137.73/38	PISTONRING STD	2
35	1100-160	WATER GAUGE SENSOR	3	128	PC137.73-35	PISTONRING STD	3
36	14R113E	VALVE,REGULATING,P R	2	129	PC137.74/11	EMME SUBABI	3
37	15301-1390	GAGE SUB ASSY OIL L	3	130	PC137.74/14	EINLASSVENTIL	6
38	162-101-2211	WIRE CABLE	3	131	PC137-73/5	DICHTUNG	3
39	162-103-0411	HANDLE,MANUAL CONTR	2	132	PC137-73-47	GASKET	3
40	171-403-0033	VENTIL,SCHUTZ	3	133	PG:3-202	THERMOSTAT	2
41	187-101-2227	DAYLIGHT	3	134	PI-MATIK 150	VAAHTOSEKOITTAJA	3
42	187-101-2617	AUX.MAIN BEAM	1	135	PP1625	COMPRESSION RING	2
43	187-201-1617	END LIGHT	3	136	PRV 73-274 700	HIDROLIK SILINDIR	6
44	1-S-252414-001	CLUTCH ASSY	3	137	REN 117063	CHAIN	3
45	22 001506	AXLE	3	138	ROQ 4V RHD 02 R1	PRESSURE OPERATED	6
46	22.130/1	HEAT EXCHANGER	3	139	ROW 4.00X8 6L HS	WHEEL W/TYRE	6
47	2405CP10	SHEEL SET.010	3	140	S21-03652	ABRREL SLEEVE ASSY	4
48	2405CPA	SHELL SET	4	141	SF37/1.7060	PRINTED WIRING BOAR	3
49	2406CPA-10	SHELL SET	3	142	SISAM .0 63	PAINELETKU	3
50	241010-49	CYLINDER HEAD GASKE	3	143	SISAM 0 50	LATKU	3

(EK-1'in devamı)

S/No	P.No	M.Adı	Malzeme Grubu	S/No	P.No	M.Adı	Malzeme Grubu
51	252414-54	EXHAUST VALVE	3	144	SK483-18	TAMİR KITI. MOTOR	2
52	276227-13	PISTONE COMPLETO	6	145	SK497/29	MOTOR.SARJ	3
53	276228-13	CONTROL ÜNİTESİ	1	146	SK-498/15	GASGET	3
54	280894-16	INTAKE MANIFOLD GAS	1	147	SK601-1/2	NOZZLE HOLDER	3
55	280896-16	PACKING PREFORMED	5	148	SK-604-13	VALVE INTAKE	6
56	285329-21	SEGMAN SET STD (RING SET P	2	149	SK631 9-2/2	PUMP.COOLING SİSTEM	3
57	285329-28	PUMP.FUELMETERING	3	150	SK642-5	RESTRICTOR,FLUID FL	3
58	2AB 004532-011	PANEL LIGHT	3	151	SK-S4550	PARTS KIT.ENGINE WA	2
59	2JA 001360-021	EQUIPMENT ROOM LIGH	3	152	SK-S6045	CUP INJECTION	3
60	3020-8	HYDROLIC,MANUEL CON	1	153	SK-S9620	BARREL AND PLUNGER	3
61	350.471/008/045G	PAINEMITTARI	1	154	SK-SC520	BRACKET, ENGINE MOUN	3
62	3C3Z 6375 AA	FLY WHEEL AND RING G	3	155	SK-SC819	PUMP.FUEL.METERING AND	3
63	3C3Z 6731 AA	FILTER ASYY-OIL	2	156	SOS-201/P44/24	REAR BLINKER	3
64	3C3Z 6A051 AA	HEATER ASSY	4	157	TR 75 SH	TURRET ASSY	4
65	3C3Z 8260 AG	HOSE ASSY	6	158	VKN L=1315	VALOMASTOSYLINT	3
66	3C3Z 8575 AA	THERMOSTAT ASSY	4	159	WAB 971 002 530 0	BRAKE ACTUATOR VALV	6
67	3C3Z 9B659 AA	HOSE AIR	6	160	XCK.01212	HORTUM	3
68	3C3Z 9N184 CA	FILTER ASSY	3	161	XCK.02978	10X16 KELEPÇE	5
69	400641-12	AMMETER	4	162	XCK.1.5004	(+) KUTUP BAŞI	3
70	4022/2	INJECTOR ASSEMBLY	4	163	XCK.10-2/9	MONOMONYUM FOSFAT	5
71	4022-2	CONTROL WHEEL	1	164	XCK.10-4-29	ANTIFIRIZ	5
72	4022-3	WATER PUMP	4	165	XCK.1-10-A22	SLIKON	5
73	4022-4	WORM AXEL	3	166	XCK.1-3090	PLASTİK YAPIŞTIRICI	5
74	47510-1081	CYLINDER,ENGINE	2	167	XCK.157686	LOCKTITE	5
75	47550-1200	CYLINDER	3	168	XCK.157894-18	CONTA	5
76	4C3Z 1216 AA	CONE AND ROLLER ASS	4	169	XCK.16/281368	KIRMIZI HIDROLIK	5
77	4C3Z 12A342 AA	GLOW PLUG	3	170	XCK.163-13	20.20 DİZ MOTOR YAGI	5
78	4C3Z 12B599 AARM	MODULE ENGINE CONTR	1	171	XCK.163-2(4)-7	(-) KUTUP BAŞI	5
79	4C3Z 8501 ABRM	PUMP ASSY WATER	4	172	XCK.171-2(2)	CO2 KURU KİMYEVİ TOZ	5
80	4C3Z 9601 AA	ELEMENT FILTER	3	173	XCK.187-1	20.40 DIZEL MOTOR YAĞI	5
81	5325001715289SX	EYELET,TURNLOCK FAS	3	174	XCK.187-2(4)-18	TP HORTUM	3
82	5C3Z 2200 AA	KIT BRAKE SHOE	3	175	XCK.187-33	8X13 KELEPÇE	5
83	5C3Z 3E764 K	RESERVOIR ASSY	6	176	XCK.18925	SIVI CONTA	5
84	5C3Z 5E212 B	CATALYST ASSY	3	177	XCK.22.130/1	10X16 KELEPÇE	5
85	5C3Z 8286 EH	HOSE ASSY	6	178	XCK.32678	LANS	3
86	5C3Z 9C968 CA	REGULATOR FUEL PRES	6	179	XCK-P102	MICRO SWITCH TANK	3
87	5C3Z 9F452 AA	VALVE ASSY	3	180	XKB-A16220	MONITOR JOY-STICK	3
88	5U2Z 1V102 A	HUB ASSY	4	181	ZF 767 49 55155	HYDR.PUMP	3
89	6C2Z 11002 AA	STARTER MOTOR ASSY	4	182	3.4001	ACTUATOR	3
90	6C3Z 10346 BA	ALTERNATOR ASSY	4	183	11783	MANYETIC PICK-UP	3
91	6C3Z 8009 BA	RADIATOR ASSY	3	184	43135	INTAKE VALVE	3
92	6C3Z 9G282 AA	PUMP ASSY FUEL	4	185	44655	TURBO CHARGER	4
93	6W576	IMPELLER TUR COMPR.	3	186	45714	PART KIT (1),DIES	2

EK-2 Uzman Personelin Derecelendirmesi

TEKNOLOJİK ÖZELLİK Altyapı Yeterliliği/Özel İşlem Gerektiren Prosess Durumu		Uzman Personel-1	Uzman Personel-2	Uzman Personel-3	Uzman Personel-4	Uzman Personel-5	Uzman Personel-6	Uzman Personel-7	Uzman Personel-8	Uzman Personel-9
Yüksek Basınç Elemanları	Tamirlik Malzemeler	7.00	5.00	5.00	2.00	5.00	7.00	3.00	3.00	5.00
Yüksek Basınç Elemanları	Kit ve Takım Malzemeler	5.00	7.00	5.00	3.00	7.00	5.00	2.00	0.33	5.00
Yüksek Basınç Elemanları	Yedek Parça Grubu	5.00	5.00	5.00	2.00	5.00	5.00	1.00	1.00	5.00
Yüksek Basınç Elemanları	Hammadde ve Sarf Malzem	5.00	5.00	5.00	5.00	5.00	5.00	3.00	5.00	5.00
Yüksek Basınç Elemanları	Kontrol Üniteleri	1.00	1.00	1.00	5.00	1.00	1.00	2.00	5.00	1.00
Tamirlik Malzemeler	Kit ve Takım Malzemeler	0.33	0.33	0.33	2.00	0.33	0.33	1.00	0.33	0.33
Tamirlik Malzemeler	Yedek Parça Grubu	0.33	0.33	0.33	2.00	0.33	0.33	1.00	0.33	0.33
Tamirlik Malzemeler	Hammadde ve Sarf Malzem	0.33	0.33	0.33	3.00	0.33	0.33	2.00	7.00	0.33
Tamirlik Malzemeler	Kontrol Üniteleri	0.11	0.11	0.14	2.00	0.11	0.11	0.33	3.00	0.14
Kit ve Takım Malzemeler	Yedek Parça Grubu	0.33	0.33	0.33	1.00	0.33	0.33	1.00	1.00	0.33
Kit ve Takım Malzemeler	Hammadde ve Sarf Malzem	3.00	3.00	3.00	3.00	3.00	3.00	2.00	5.00	3.00
Kit ve Takım Malzemeler	Kontrol Üniteleri	0.33	0.20	0.20	3.00	0.20	0.33	1.00	5.00	0.20
Yedek Parça Grubu	Hammadde ve Sarf Malzem	5.00	5.00	3.00	3.00	5.00	5.00	2.00	7.00	3.00
Yedek Parça Grubu	Kontrol Üniteleri	0.14	0.20	0.20	5.00	0.20	0.14	1.00	5.00	0.20
Hammadde ve Sarf Malzem	Kontrol Üniteleri	0.33	0.20	0.33	1.00	0.20	0.33	0.50	0.20	0.33

ÜRETİM ETKİNLİĞİ Doğrudan Etkisi Olan/Dolaylı Etkisi Olan		Uzman Personel-1	Uzman Personel-2	Uzman Personel-3	Uzman Personel-4	Uzman Personel-5	Uzman Personel-6	Uzman Personel-7	Uzman Personel-8	Uzman Personel-9
Yüksek Basınç Elemanları	Tamirlik Malzemeler	7.00	5.00	3.00	0.50	5.00	7.00	3.00	3.00	3.00
Yüksek Basınç Elemanları	Kit ve Takım Malzemeler	7.00	9.00	9.00	3.00	9.00	7.00	2.00	1.00	9.00
Yüksek Basınç Elemanları	Yedek Parça Grubu	7.00	5.00	3.00	3.00	5.00	7.00	1.00	1.00	3.00
Yüksek Basınç Elemanları	Hammadde ve Sarf Malzem	7.00	9.00	9.00	7.00	9.00	7.00	3.00	5.00	9.00
Yüksek Basınç Elemanları	Kontrol Üniteleri	5.00	5.00	5.00	3.00	5.00	5.00	2.00	7.00	5.00
Tamirlik Malzemeler	Kit ve Takım Malzemeler	5.00	5.00	5.00	3.00	5.00	5.00	1.00	1.00	5.00
Tamirlik Malzemeler	Yedek Parça Grubu	1.00	1.00	1.00	3.00	1.00	1.00	1.00	0.33	1.00
Tamirlik Malzemeler	Hammadde ve Sarf Malzem	5.00	7.00	7.00	3.00	7.00	5.00	2.00	5.00	7.00
Tamirlik Malzemeler	Kontrol Üniteleri	0.33	0.33	0.33	3.00	0.33	0.33	0.33	5.00	0.33
Kit ve Takım Malzemeler	Yedek Parça Grubu	0.33	0.33	0.33	0.20	0.33	0.33	1.00	0.33	0.33
Kit ve Takım Malzemeler	Hammadde ve Sarf Malzem	3.00	3.00	3.00	2.00	3.00	3.00	2.00	7.00	3.00
Kit ve Takım Malzemeler	Kontrol Üniteleri	0.14	0.14	0.20	7.00	0.14	0.14	1.00	3.00	0.20
Yedek Parça Grubu	Hammadde ve Sarf Malzem	3.00	5.00	5.00	3.00	5.00	3.00	2.00	7.00	5.00
Yedek Parça Grubu	Kontrol Üniteleri	0.33	0.33	0.33	3.00	0.33	0.33	1.00	5.00	0.33
Hammadde ve Sarf Malzem	Kontrol Üniteleri	0.14	0.14	0.14	3.00	0.14	0.14	0.50	0.33	0.14

(EK-2'nin devamı)

ÇALIŞMA EMNİYETİ VE GÜVENİ Kullanım Yeri/Sertifikasyon Gereksinimleri		Uzman Personel-1	Uzman Personel-2	Uzman Personel-3	Uzman Personel-4	Uzman Personel-5	Uzman Personel-6	Uzman Personel-7	Uzman Personel-8	Uzman Personel-9
Yüksek Basınç Elemanları	Tamirlik Malzemeler	7.00	5.00	5.00	5.00	5.00	7.00	3.00	3.00	5.00
Yüksek Basınç Elemanları	Kit ve Takım Malzemeler	7.00	7.00	5.00	7.00	7.00	7.00	2.00	1.00	5.00
Yüksek Basınç Elemanları	Yedek Parça Grubu	5.00	5.00	5.00	5.00	5.00	5.00	1.00	1.00	5.00
Yüksek Basınç Elemanları	Hammadde ve Sarf Malzem	7.00	5.00	5.00	5.00	5.00	7.00	3.00	3.00	5.00
Yüksek Basınç Elemanları	Kontrol Üniteleri	1.00	1.00	1.00	0.33	1.00	1.00	2.00	5.00	1.00
Tamirlik Malzemeler	Kit ve Takım Malzemeler	5.00	5.00	5.00	2.00	5.00	5.00	1.00	0.33	5.00
Tamirlik Malzemeler	Yedek Parça Grubu	0.33	0.20	0.20	3.00	0.20	0.33	1.00	0.33	0.20
Tamirlik Malzemeler	Hammadde ve Sarf Malzem	3.00	3.00	3.00	3.00	3.00	3.00	2.00	3.00	3.00
Tamirlik Malzemeler	Kontrol Üniteleri	0.14	0.20	0.33	0.33	0.20	0.14	0.33	5.00	0.33
Kit ve Takım Malzemeler	Yedek Parça Grubu	0.33	0.33	0.33	0.50	0.33	0.33	1.00	1.00	0.33
Kit ve Takım Malzemeler	Hammadde ve Sarf Malzem	3.00	3.00	3.00	1.00	3.00	3.00	2.00	7.00	3.00
Kit ve Takım Malzemeler	Kontrol Üniteleri	0.20	0.11	0.14	0.14	0.11	0.20	1.00	5.00	0.14
Yedek Parça Grubu	Hammadde ve Sarf Malzem	5.00	3.00	3.00	2.00	3.00	5.00	2.00	5.00	3.00
Yedek Parça Grubu	Kontrol Üniteleri	0.14	0.20	0.33	0.14	0.20	0.14	1.00	3.00	0.33
Hammadde ve Sarf Malzem	Kontrol Üniteleri	0.11	0.11	0.14	0.14	0.11	0.11	0.50	0.33	0.14

KATMA DEĞER/MALİYET ETKİNLİK Maliyet-Fiyat Durumu/Teknik Doküman Maliyeti		Uzman Personel-1	Uzman Personel-2	Uzman Personel-3	Uzman Personel-4	Uzman Personel-5	Uzman Personel-6	Uzman Personel-7	Uzman Personel-8	Uzman Personel-9
Yüksek Basınç Elemanları	Tamirlik Malzemeler	3.00	3.00	5.00	1.00	3.00	3.00	3.00	3.00	5.00
Yüksek Basınç Elemanları	Kit ve Takım Malzemeler	5.00	3.00	3.00	5.00	3.00	5.00	2.00	0.33	3.00
Yüksek Basınç Elemanları	Yedek Parça Grubu	5.00	5.00	3.00	5.00	5.00	5.00	1.00	0.33	3.00
Yüksek Basınç Elemanları	Hammadde ve Sarf Malzem	3.00	3.00	3.00	7.00	3.00	3.00	3.00	7.00	3.00
Yüksek Basınç Elemanları	Kontrol Üniteleri	0.33	1.00	1.00	5.00	1.00	0.33	2.00	7.00	1.00
Tamirlik Malzemeler	Kit ve Takım Malzemeler	1.00	1.00	1.00	3.00	1.00	1.00	1.00	0.33	1.00
Tamirlik Malzemeler	Yedek Parça Grubu	0.33	0.33	0.33	3.00	0.33	0.33	1.00	0.20	0.33
Tamirlik Malzemeler	Hammadde ve Sarf Malzem	0.33	0.33	0.33	4.00	0.33	0.33	2.00	7.00	0.33
Tamirlik Malzemeler	Kontrol Üniteleri	0.20	0.33	0.33	3.00	0.33	0.20	0.33	0.50	0.33
Kit ve Takım Malzemeler	Yedek Parça Grubu	0.33	0.33	0.33	0.50	0.33	0.33	1.00	1.00	0.33
Kit ve Takım Malzemeler	Hammadde ve Sarf Malzem	0.33	0.33	0.33	2.00	0.33	0.33	2.00	7.00	0.33
Kit ve Takım Malzemeler	Kontrol Üniteleri	0.20	0.20	0.33	1.00	0.20	0.20	1.00	7.00	0.33
Yedek Parça Grubu	Hammadde ve Sarf Malzem	5.00	3.00	3.00	3.00	3.00	5.00	2.00	9.00	3.00
Yedek Parça Grubu	Kontrol Üniteleri	0.33	0.33	0.33	1.00	0.33	0.33	1.00	7.00	0.33
Hammadde ve Sarf Malzem	Kontrol Üniteleri	0.20	0.33	0.33	0.50	0.33	0.20	0.50	0.14	0.33

(EK-2'nin devamı)

İHTİYAÇ DURUMU/KULLANIM MİKTARI Yıllık Kullanım Miktarı/ Çevrim Yedeği Sağlanabilirliği /Arıza Sıklık Durumu		Uzman Personel-1	Uzman Personel-2	Uzman Personel-3	Uzman Personel-4	Uzman Personel-5	Uzman Personel-6	Uzman Personel-7	Uzman Personel-8	Uzman Personel-9
Yüksek Basınç Elemanları	Tamirlik Malzemeler	3.00	3.00	3.00	0.50	3.00	3.00	3.00	5.00	3.00
Yüksek Basınç Elemanları	Kit ve Takım Malzemeler	3.00	3.00	5.00	0.33	3.00	3.00	2.00	0.20	5.00
Yüksek Basınç Elemanları	Yedek Parça Grubu	3.00	3.00	3.00	0.50	3.00	3.00	1.00	0.33	3.00
Yüksek Basınç Elemanları	Hammadde ve Sarf Malzem	3.00	3.00	5.00	0.33	3.00	3.00	3.00	7.00	5.00
Yüksek Basınç Elemanları	Kontrol Üniteleri	1.00	1.00	1.00	1.00	1.00	1.00	2.00	9.00	1.00
Tamirlik Malzemeler	Kit ve Takım Malzemeler	1.00	1.00	1.00	2.00	1.00	1.00	1.00	0.33	1.00
Tamirlik Malzemeler	Yedek Parça Grubu	1.00	1.00	1.00	2.00	1.00	1.00	1.00	0.20	1.00
Tamirlik Malzemeler	Hammadde ve Sarf Malzem	0.33	0.33	0.33	3.00	0.33	0.33	2.00	7.00	0.33
Tamirlik Malzemeler	Kontrol Üniteleri	0.20	0.33	0.33	2.00	0.33	0.20	0.33	7.00	0.33
Kit ve Takım Malzemeler	Yedek Parça Grubu	0.33	0.33	0.33	3.00	0.33	0.33	1.00	1.00	0.33
Kit ve Takım Malzemeler	Hammadde ve Sarf Malzem	0.33	0.33	0.33	1.00	0.33	0.33	2.00	9.00	0.33
Kit ve Takım Malzemeler	Kontrol Üniteleri	0.20	0.33	0.33	0.33	0.33	0.20	1.00	7.00	0.33
Yedek Parça Grubu	Hammadde ve Sarf Malzem	3.00	3.00	3.00	0.50	3.00	3.00	2.00	9.00	3.00
Yedek Parça Grubu	Kontrol Üniteleri	0.20	0.33	0.33	1.00	0.33	0.20	1.00	5.00	0.33
Hammadde ve Sarf Malzem	Kontrol Üniteleri	0.20	0.33	0.33	0.50	0.33	0.20	0.50	0.14	0.33

TEDARİK DURUMU/YETERLİLİĞİ Tedarik Sürdürülebilirliği/Tedarik Süresi /Tedarik Altarnatifi /İthalat Bağımlılığı		Uzman Personel-1	Uzman Personel-2	Uzman Personel-3	Uzman Personel-4	Uzman Personel-5	Uzman Personel-6	Uzman Personel-7	Uzman Personel-8	Uzman Personel-9
Yüksek Basınç Elemanları	Tamirlik Malzemeler	3.00	3.00	3.00	2.00	3.00	3.00	3.00	5.00	3.00
Yüksek Basınç Elemanları	Kit ve Takım Malzemeler	3.00	5.00	5.00	5.00	5.00	3.00	2.00	0.20	5.00
Yüksek Basınç Elemanları	Yedek Parça Grubu	3.00	3.00	5.00	3.00	3.00	3.00	1.00	0.33	5.00
Yüksek Basınç Elemanları	Hammadde ve Sarf Malzem	5.00	3.00	5.00	7.00	3.00	5.00	3.00	7.00	5.00
Yüksek Basınç Elemanları	Kontrol Üniteleri	5.00	3.00	3.00	2.00	3.00	5.00	2.00	7.00	3.00
Tamirlik Malzemeler	Kit ve Takım Malzemeler	1.00	1.00	1.00	3.00	1.00	1.00	1.00	0.33	1.00
Tamirlik Malzemeler	Yedek Parça Grubu	0.20	0.33	0.33	2.00	0.33	0.20	1.00	0.33	0.33
Tamirlik Malzemeler	Hammadde ve Sarf Malzem	3.00	3.00	3.00	5.00	3.00	3.00	2.00	7.00	3.00
Tamirlik Malzemeler	Kontrol Üniteleri	0.33	0.33	0.33	3.00	0.33	0.33	0.33	7.00	0.33
Kit ve Takım Malzemeler	Yedek Parça Grubu	0.33	0.33	0.33	0.50	0.33	0.33	1.00	0.33	0.33
Kit ve Takım Malzemeler	Hammadde ve Sarf Malzem	1.00	1.00	1.00	2.00	1.00	1.00	2.00	7.00	1.00
Kit ve Takım Malzemeler	Kontrol Üniteleri	0.20	0.33	0.33	0.50	0.33	0.20	1.00	5.00	0.33
Yedek Parça Grubu	Hammadde ve Sarf Malzem	3.00	3.00	3.00	3.00	3.00	3.00	2.00	7.00	3.00
Yedek Parça Grubu	Kontrol Üniteleri	0.20	0.33	0.33	1.00	0.33	0.20	1.00	5.00	0.33
Hammadde ve Sarf Malzem	Kontrol Üniteleri	0.33	0.33	0.20	0.33	0.33	0.33	0.50	0.20	0.20

(EK-2'nin devamı)

MEVCUT İŞ GÜCÜ/İHTİSAS DURUMU İş Gücü Kapasite Durumu/Kritik İhtisas Durumu		Uzman Personel-1	Uzman Personel-2	Uzman Personel-3	Uzman Personel-4	Uzman Personel-5	Uzman Personel-6	Uzman Personel-7	Uzman Personel-8	Uzman Personel-9
Yüksek Basınç Elemanları	Tamirlik Malzemeler	3.00	3.00	5.00	2.00	3.00	3.00	3.00	7.00	5.00
Yüksek Basınç Elemanları	Kit ve Takım Malzemeler	5.00	3.00	5.00	2.00	3.00	5.00	2.00	0.20	5.00
Yüksek Basınç Elemanları	Yedek Parça Grubu	5.00	3.00	3.00	2.00	3.00	5.00	1.00	0.33	3.00
Yüksek Basınç Elemanları	Hammadde ve Sarf Malzem	3.00	5.00	5.00	2.00	5.00	3.00	3.00	7.00	5.00
Yüksek Basınç Elemanları	Kontrol Üniteleri	1.00	1.00	1.00	2.00	1.00	1.00	2.00	7.00	1.00
Tamirlik Malzemeler	Kit ve Takım Malzemeler	3.00	3.00	3.00	2.00	3.00	3.00	1.00	0.33	3.00
Tamirlik Malzemeler	Yedek Parça Grubu	1.00	1.00	1.00	1.00	1.00	1.00	1.00	0.33	1.00
Tamirlik Malzemeler	Hammadde ve Sarf Malzem	1.00	1.00	1.00	2.00	1.00	1.00	2.00	7.00	1.00
Tamirlik Malzemeler	Kontrol Üniteleri	0.20	0.33	0.33	1.00	0.33	0.20	0.33	5.00	0.33
Kit ve Takım Malzemeler	Yedek Parça Grubu	0.33	0.33	0.20	1.00	0.33	0.33	1.00	1.00	0.20
Kit ve Takım Malzemeler	Hammadde ve Sarf Malzem	1.00	1.00	1.00	1.00	1.00	1.00	2.00	9.00	1.00
Kit ve Takım Malzemeler	Kontrol Üniteleri	0.33	0.20	0.20	1.00	0.20	0.33	1.00	5.00	0.20
Yedek Parça Grubu	Hammadde ve Sarf Malzem	1.00	1.00	3.00	1.00	1.00	1.00	2.00	9.00	3.00
Yedek Parça Grubu	Kontrol Üniteleri	0.33	0.20	0.20	1.00	0.20	0.33	1.00	5.00	0.20
Hammadde ve Sarf Malzem	Kontrol Üniteleri	1.00	1.00	0.33	1.00	1.00	1.00	0.50	0.14	0.33

EK-3 Çalışma Kapsamında Yazılan Makrolar

Makro-1:

Yapay sinir ağlarının sipariş planlarının hazırlanmasında kullanılmıştır.

```
Dim SI, HucD, KI
Dim SatSay, SutSay, j, k, l, m, n, g, b, BasS, BitS
Set BasS = InputBox(" Başlangıç sayısını yazınız")
Set BitS = InputBox(" Bitiş sayısı")
S
  SI = 1 / 2
  n = 3
  g = 1
  For i = 3 To 1430 ' for i=3 to "sayfa2 en son satır numarsı"
     n = n + 1
     If n < 134 Then
        For SutSay = 3 To 14
           m = SutSay + 13
           HucD = Sayfa2.Cells(i, SutSay)
           If HucD >= SI Then
              KI = 1
           Else
              KI = 0
           End If
           Sayfa1.Cells(n, m) = KI
        Next
     Else
'Sapma sonuçları sheet3 kopyalancak.
     n = 4
     b = i - 2
     g = g + 1
     Sayfa3.Cells(1, g) = SI
     Sayfa3.Cells(2, g) = Sayfa2.Cells(b, 2)
     Sayfa3.Cells(3, g) = Sayfa1.Cells(134, 107)
     For l = 4 To 133
        Sayfa3.Cells(l, g) = Sayfa1.Cells(l, 107)
     Next

     For SutSay = 3 To 14
           m = SutSay + 13
           HucD = Sayfa2.Cells(i, SutSay)
           If HucD >= SI Then
              KI = 1
           Else
              KI = 0
           End If
```

(EK-3'ün devamı)

```
            Sayfa1.Cells(4, m) = KI
          Next
        End If
    Next
```

Makro-2:

Ağların WW toplam maliyetlerinden sapma yüzdelerinin hesaplanmasında kullanılmıştır.

```
Dim SI, HucD, KI
Dim SatSay, SutSay, j, k, l, m, n, g, b, BasS, BitS, OPNet, OPNet1, ANN, sapma
sapma = 1
g = 1
OPNet = 2 ' SI nın en büyük değerinden büyük değere atanmalıdır.
SI = 0.5
'Image3.Width = SI
' Bu makro sayfa2 de yer alan 130 satırlık ysa siparişinin 0 1 dönüşümünü yapar.' 0 1
dönüşümü ---> bu dönüşüm her hücre için YSA tahmini>=SI ise 1 else 0 olarak
hesaplanır.  0 1 dönüşümleri sayfa1 de yer alan 4,16x 133,27 satırları arasına yapıştırır.'
Ardından 107. sutunda ilgili ağın ww maliyetinde sapmaları otomatik olarak hücrelere
girilen' formüller fasıtası ile oluşturulur.' 135x107 satırda ağın ww toplam maliyetinden
standart sapması hafızaya kopyalanarı.' sayfa 3 de ağ numarası ile "SI" ile kayıt edilir.'
SatSay değişkenine atanacak değer sayfa 1 sonuncu satırın numarası olmalıdır.
      n = 3
            For i = 1 To 56164 ' "sayfa2 en son satır numarsı"
         n = n + 1
         If n < 134 Then
            For SutSay = 3 To 14
               m = SutSay + 13
               HucD = Sayfa2.Cells(i, SutSay)
               If HucD >= SI Then
                  KI = 1
               Else
                  KI = 0
               End If
               Sayfa1.Cells(n, m) = KI

            Next
         Else
   'Sapma sonuçları sheet3 kopyalancak.
            n = 4
            b = i - 2
            g = g + 1
   'bu kısımdaki kodlar ağ numarasını sı değerini ve sapmayı alta alta satırlar olarak
yazar
            Sayfa3.Cells(g, 2) = SI 'SI
```

(EK-3'ün devamı)

```
            Sayfa3.Cells(g, 3) = Sayfa2.Cells(b, 2) 'ağno
            Sayfa3.Cells(g, 4) = Sayfa1.Cells(134, 43) 'sapma
    'Set Sayfa3.Cells(g, 4) = ActiveCell
            If Sayfa3.Cells(g, 4) < sapma Then
            sapma = Sayfa3.Cells(g, 4)
            Sayfa3.Cells(2, 6) = SI 'SI
            Sayfa3.Cells(2, 7) = Sayfa2.Cells(b, 2) 'ağno
            Sayfa3.Cells(2, 8) = Sayfa1.Cells(134, 43) 'sapma
            End If
            For SutSay = 3 To 14
              m = SutSay + 13
               HucD = Sayfa2.Cells(i, SutSay)
               If HucD >= SI Then
                  KI = 1
               Else
                  KI = 0
               End If
               Sayfa1.Cells(4, m) = KI
            Next
          End If
       Next
```

Makro-3

WİNQSB çözümlerinden alınan verileri Excel ortamında düzenlemek için kullanıldı

```
Sub U1()
Dim i, j, k, l, m, n
Dim st, ad, yıl, p1, p2, p3, p4, p5, p6, p7, p8, p9, p10, p11, p12 As String
j = 1
For i = 4 To 933
st = Sayfa8.Cells(i, 1)
ad = Sayfa8.Cells(i, 2)
yıl = Sayfa8.Cells(i, 3)
p1 = Sayfa8.Cells(i, 4)
p2 = Sayfa8.Cells(i, 5)
p3 = Sayfa8.Cells(i, 6)
p4 = Sayfa8.Cells(i, 7)
p5 = Sayfa8.Cells(i, 8)
p6 = Sayfa8.Cells(i, 9)
p7 = Sayfa8.Cells(i, 10)
p8 = Sayfa8.Cells(i, 11)
p9 = Sayfa8.Cells(i, 12)
p10 = Sayfa8.Cells(i, 13)
p11 = Sayfa8.Cells(i, 14)
p12 = Sayfa8.Cells(i, 15)
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
```

(EK-3'ün devamı)

```
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p1
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p2
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p3
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p4
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p5
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p6
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p7
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p8
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p9
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p10
```

(EK-3'ün devamı)

```
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p11
j = j + 1
Sayfa9.Cells(j, 1) = st
Sayfa9.Cells(j, 2) = ad
Sayfa9.Cells(j, 3) = yıl
Sayfa9.Cells(j, 4) = p12
j = j + 1
Next

End Sub

Sub U3()
Dim j, k
j = 1
For k = 61 To 11160
If j = 61 Then
j = 1
Sayfa9.Cells(k, 5) = Sayfa9.Cells(j, 5)
j = j + 1
Else
Sayfa9.Cells(k, 5) = Sayfa9.Cells(j, 5)
j = j + 1
End If
Next
End Sub

Sub U2()
Dim i, j
Dim sn, ad As String
For i = 5 To 930
For j = 4 To 186
If Sayfa4.Cells(j, 3) = Sayfa10.Cells(i, 2) Then
Sayfa10.Cells(i, 3) = Sayfa4.Cells(j, 6)
End If
Next j
Next i
End Sub
```

EK-4 Ağ Yapıları

Ağ Nu.	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu	Komşuluk	Karşılaştırma Kuralı	Metric
1	ÇKA	Momentum	TanhAxon	-	-	-
2	ÇKA	Momentum	Sigmoid Axon	-	-	-
3	ÇKA	Momentum	Linear TanhAxon	-	-	-
4	ÇKA	Momentum	Linear SigmoidAxon	-	-	-
5	ÇKA	Momentum	Soft MaxAxon	-	-	-
6	ÇKA	Momentum	BiasAxon	-	-	-
7	ÇKA	Momentum	LinearAxon	-	-	-
8	ÇKA	Momentum	Axon	-	-	-
9	ÇKA	Step	TanhAxon	-	-	-
10	ÇKA	ConjugateGradiant	TanhAxon	-	-	-
11	ÇKA	QuickProp	TanhAxon	-	-	-
12	ÇKA	DeltaBarDelta	TanhAxon	-	-	-
13	ÇKA	Step	Sigmoid Axon	-	-	-
14	ÇKA	ConjugateGradiant	Sigmoid Axon	-	-	-
15	ÇKA	QuickProp	Sigmoid Axon	-	-	-
16	ÇKA	DeltaBarDelta	Sigmoid Axon	-	-	-
17	ÇKA	Step	Linear TanhAxon	-	-	-
18	ÇKA	ConjugateGradiant	Linear TanhAxon	-	-	-
19	ÇKA	QuickProp	Linear TanhAxon	-	-	-
20	ÇKA	DeltaBarDelta	Linear TanhAxon	-	-	-
21	ÇKA	Step	LinearSigmoidAxon	-	-	-
22	ÇKA	ConjugateGradiant	LinearSigmoidAxon	-	-	-
23	ÇKA	QuickProp	LinearSigmoidAxon	-	-	-
24	ÇKA	DeltaBarDelta	LinearSigmoidAxon	-	-	-
25	ÇKA	Step	BiasAxon	-	-	-
26	ÇKA	ConjugateGradiant	BiasAxon	-	-	-
27	ÇKA	QuickProp	BiasAxon	-	-	-
28	ÇKA	DeltaBarDelta	BiasAxon	-	-	-
29	ÇKA	Step	LinearAxon	-	-	-
30	ÇKA	ConjugateGradiant	LinearAxon	-	-	-
31	ÇKA	QuickProp	LinearAxon	-	-	-
32	ÇKA	DeltaBarDelta	LinearAxon	-	-	-
33	ÇKA	Step	SoftMaxAxon	-	-	-
34	ÇKA	ConjugateGradiant	SoftMaxAxon	-	-	-
35	ÇKA	QuickProp	SoftMaxAxon	-	-	-
36	ÇKA	DeltaBarDelta	SoftMaxAxon	-	-	-
37	ÇKA	Step	Axon	-	-	-
38	ÇKA	ConjugateGradiant	Axon	-	-	-
39	ÇKA	QuickProp	Axon	-	-	-
40	ÇKA	DeltaBarDelta	Axon	-	-	-
41	SOFM	Momentum	TanhAxon	DiomendKohonenFull	-	-
42	SOFM	Momentum	TanhAxon	LinedKohonenFull	-	-
43	SOFM	Momentum	TanhAxon	SequreKohonenFull	-	-
44	SOFM	Step	TanhAxon	DiomendKohonenFull	-	-
45	SOFM	Step	TanhAxon	LinedKohonenFull	-	-
46	SOFM	Step	TanhAxon	SequreKohonenFull	-	-
47	SOFM	ConjugateGradiant	TanhAxon	DiomendKohonenFull	-	-
48	SOFM	ConjugateGradiant	TanhAxon	LinedKohonenFull	-	-
49	SOFM	ConjugateGradiant	TanhAxon	SequreKohonenFull	-	-
50	SOFM	QuickProp	TanhAxon	DiomendKohonenFull	-	-
51	SOFM	QuickProp	TanhAxon	LinedKohonenFull	-	-
52	SOFM	QuickProp	TanhAxon	SequreKohonenFull	-	-
53	SOFM	DeltaBarDelta	TanhAxon	DiomendKohonenFull	-	-
54	SOFM	DeltaBarDelta	TanhAxon	LinedKohonenFull	-	-
55	SOFM	DeltaBarDelta	TanhAxon	SequreKohonenFull	-	-
56	SOFM	Momentum	Sigmoid Axon	DiomendKohonenFull	-	-
57	SOFM	Momentum	Sigmoid Axon	LinedKohonenFull	-	-
58	SOFM	Step	Sigmoid Axon	DiomendKohonenFull	-	-
59	SOFM	ConjugateGradiant	Sigmoid Axon	DiomendKohonenFull	-	-
60	SOFM	QuickProp	Sigmoid Axon	DiomendKohonenFull	-	-
61	SOFM	DeltaBarDelta	Sigmoid Axon	DiomendKohonenFull	-	-

(EK-4'ün devamı)

Ağ Nu.	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu	Komşuluk	Karşılaştırma Kuralı	Metric
62	SOFM	Momentum	Linear TanhAxon	DiomendKohonenFull	-	-
63	SOFM	Step	Linear TanhAxon	DiomendKohonenFull	-	-
64	SOFM	ConjugateGradiant	Linear TanhAxon	DiomendKohonenFull	-	-
65	SOFM	QuickProp	Linear TanhAxon	DiomendKohonenFull	-	-
66	SOFM	DeltaBarDelta	Linear TanhAxon	DiomendKohonenFull	-	-
67	SOFM	Momentum	Linear SigmoidAxon	DiomendKohonenFull	-	-
68	SOFM	Step	Linear SigmoidAxon	DiomendKohonenFull	-	-
69	SOFM	ConjugateGradiant	Linear SigmoidAxon	DiomendKohonenFull	-	-
70	SOFM	QuickProp	Linear SigmoidAxon	DiomendKohonenFull	-	-
71	SOFM	DeltaBarDelta	Linear SigmoidAxon	DiomendKohonenFull	-	-
72	SOFM	Momentum	Soft MaxAxon	DiomendKohonenFull	-	-
73	SOFM	Step	Soft MaxAxon	DiomendKohonenFull	-	-
74	SOFM	ConjugateGradiant	Soft MaxAxon	DiomendKohonenFull	-	-
75	SOFM	QuickProp	Soft MaxAxon	DiomendKohonenFull	-	-
76	SOFM	DeltaBarDelta	Soft MaxAxon	DiomendKohonenFull	-	-
77	SOFM	Momentum	BiasAxon	DiomendKohonenFull	-	-
78	SOFM	Step	BiasAxon	DiomendKohonenFull	-	-
79	SOFM	ConjugateGradiant	BiasAxon	DiomendKohonenFull	-	-
80	SOFM	QuickProp	BiasAxon	DiomendKohonenFull	-	-
81	SOFM	DeltaBarDelta	BiasAxon	DiomendKohonenFull	-	-
82	SOFM	Momentum	LinearAxon	DiomendKohonenFull	-	-
83	SOFM	Step	LinearAxon	DiomendKohonenFull	-	-
84	SOFM	ConjugateGradiant	LinearAxon	DiomendKohonenFull	-	-
85	SOFM	QuickProp	LinearAxon	DiomendKohonenFull	-	-
86	SOFM	DeltaBarDelta	LinearAxon	DiomendKohonenFull	-	-
87	SOFM	Momentum	Axon	DiomendKohonenFull	-	-
88	SOFM	Step	Axon	DiomendKohonenFull	-	-
89	SOFM	ConjugateGradiant	Axon	DiomendKohonenFull	-	-
90	SOFM	QuickProp	Axon	DiomendKohonenFull	-	-
91	SOFM	DeltaBarDelta	Axon	DiomendKohonenFull	-	-
92	SOFM	Step	Sigmoid Axon	LinedKohonenFull	-	-
93	SOFM	ConjugateGradiant	Sigmoid Axon	LinedKohonenFull	-	-
94	SOFM	QuickProp	Sigmoid Axon	LinedKohonenFull	-	-
95	SOFM	DeltaBarDelta	Sigmoid Axon	LinedKohonenFull	-	-
96	SOFM	Momentum	Linear TanhAxon	LinedKohonenFull	-	-
97	SOFM	Step	Linear TanhAxon	LinedKohonenFull	-	-
98	SOFM	ConjugateGradiant	Linear TanhAxon	LinedKohonenFull	-	-
99	SOFM	QuickProp	Linear TanhAxon	LinedKohonenFull	-	-
100	SOFM	DeltaBarDelta	Linear TanhAxon	LinedKohonenFull	-	-
101	SOFM	Momentum	Linear SigmoidAxon	LinedKohonenFull	-	-
102	SOFM	Step	Linear SigmoidAxon	LinedKohonenFull	-	-
103	SOFM	ConjugateGradiant	Linear SigmoidAxon	LinedKohonenFull	-	-
104	SOFM	QuickProp	Linear SigmoidAxon	LinedKohonenFull	-	-
105	SOFM	DeltaBarDelta	Linear SigmoidAxon	LinedKohonenFull	-	-
106	SOFM	Momentum	Soft MaxAxon	LinedKohonenFull	-	-
107	SOFM	Step	Soft MaxAxon	LinedKohonenFull	-	-
108	SOFM	ConjugateGradiant	Soft MaxAxon	LinedKohonenFull	-	-
109	SOFM	QuickProp	Soft MaxAxon	LinedKohonenFull	-	-
110	SOFM	DeltaBarDelta	Soft MaxAxon	LinedKohonenFull	-	-
111	SOFM	Momentum	BiasAxon	LinedKohonenFull	-	-
112	SOFM	Step	BiasAxon	LinedKohonenFull	-	-
113	SOFM	ConjugateGradiant	BiasAxon	LinedKohonenFull	-	-
114	SOFM	QuickProp	BiasAxon	LinedKohonenFull	-	-
115	SOFM	DeltaBarDelta	BiasAxon	LinedKohonenFull	-	-
116	SOFM	Momentum	LinearAxon	LinedKohonenFull	-	-
117	SOFM	Step	LinearAxon	LinedKohonenFull	-	-
118	SOFM	ConjugateGradiant	LinearAxon	LinedKohonenFull	-	-
119	SOFM	QuickProp	LinearAxon	LinedKohonenFull	-	-
120	SOFM	DeltaBarDelta	LinearAxon	LinedKohonenFull	-	-
121	SOFM	Momentum	Axon	LinedKohonenFull	-	-
122	SOFM	Step	Axon	LinedKohonenFull	-	-

(EK-4'ün devamı)

Ağ Nu.	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu	Komşuluk	Karşılaştırma Kuralı	Metric
123	SOFM	ConjugateGradiant	Axon	LinedKohonenFull	-	-
124	SOFM	QuickProp	Axon	LinedKohonenFull	-	-
125	SOFM	DeltaBarDelta	Axon	LinedKohonenFull	-	-
126	SOFM	Momentum	Sigmoid Axon	SequreKohonenFull	-	-
127	SOFM	Step	Sigmoid Axon	SequreKohonenFull	-	-
128	SOFM	ConjugateGradiant	Sigmoid Axon	SequreKohonenFull	-	-
129	SOFM	QuickProp	Sigmoid Axon	SequreKohonenFull	-	-
130	SOFM	DeltaBarDelta	Sigmoid Axon	SequreKohonenFull	-	-
131	SOFM	Momentum	Linear TanhAxon	SequreKohonenFull	-	-
132	SOFM	Step	Linear TanhAxon	SequreKohonenFull	-	-
133	SOFM	ConjugateGradiant	Linear TanhAxon	SequreKohonenFull	-	-
134	SOFM	QuickProp	Linear TanhAxon	SequreKohonenFull	-	-
135	SOFM	DeltaBarDelta	Linear TanhAxon	SequreKohonenFull	-	-
136	SOFM	Momentum	Linear SigmoidAxon	SequreKohonenFull	-	-
137	SOFM	Step	Linear SigmoidAxon	SequreKohonenFull	-	-
138	SOFM	ConjugateGradiant	Linear SigmoidAxon	SequreKohonenFull	-	-
139	SOFM	QuickProp	Linear SigmoidAxon	SequreKohonenFull	-	-
140	SOFM	DeltaBarDelta	Linear SigmoidAxon	SequreKohonenFull	-	-
141	SOFM	Momentum	Soft MaxAxon	SequreKohonenFull	-	-
142	SOFM	Step	Soft MaxAxon	SequreKohonenFull	-	-
143	SOFM	ConjugateGradiant	Soft MaxAxon	SequreKohonenFull	-	-
144	SOFM	QuickProp	Soft MaxAxon	SequreKohonenFull	-	-
145	SOFM	DeltaBarDelta	Soft MaxAxon	SequreKohonenFull	-	-
146	SOFM	Momentum	BiasAxon	SequreKohonenFull	-	-
147	SOFM	Step	BiasAxon	SequreKohonenFull	-	-
148	SOFM	ConjugateGradiant	BiasAxon	SequreKohonenFull	-	-
149	SOFM	QuickProp	BiasAxon	SequreKohonenFull	-	-
150	SOFM	DeltaBarDelta	BiasAxon	SequreKohonenFull	-	-
151	SOFM	Momentum	LinearAxon	SequreKohonenFull	-	-
152	SOFM	Step	LinearAxon	SequreKohonenFull	-	-
153	SOFM	ConjugateGradiant	LinearAxon	SequreKohonenFull	-	-
154	SOFM	QuickProp	LinearAxon	SequreKohonenFull	-	-
155	SOFM	DeltaBarDelta	LinearAxon	SequreKohonenFull	-	-
156	SOFM	Momentum	Axon	SequreKohonenFull	-	-
157	SOFM	Step	Axon	SequreKohonenFull	-	-
158	SOFM	ConjugateGradiant	Axon	SequreKohonenFull	-	-
159	SOFM	QuickProp	Axon	SequreKohonenFull	-	-
160	SOFM	DeltaBarDelta	Axon	SequreKohonenFull	-	-
161	RBN	Momentum	Axon	-	ConscienceFull	DotPrudoct
162	RBN	Step	Axon	-	ConscienceFull	DotPrudoct
163	RBN	ConjugateGradiant	Axon	-	ConscienceFull	DotPrudoct
164	RBN	QuickProp	Axon	-	ConscienceFull	DotPrudoct
165	RBN	DeltaBarDelta	Axon	-	ConscienceFull	DotPrudoct
166	RBN	Momentum	BiasAxon	-	ConscienceFull	DotPrudoct
167	RBN	Step	BiasAxon	-	ConscienceFull	DotPrudoct
168	RBN	ConjugateGradiant	BiasAxon	-	ConscienceFull	DotPrudoct
169	RBN	QuickProp	BiasAxon	-	ConscienceFull	DotPrudoct
170	RBN	DeltaBarDelta	BiasAxon	-	ConscienceFull	DotPrudoct
171	RBN	Momentum	Linear SigmoidAxon	-	ConscienceFull	DotPrudoct
172	RBN	Step	Linear SigmoidAxon	-	ConscienceFull	DotPrudoct
173	RBN	ConjugateGradiant	Linear SigmoidAxon	-	ConscienceFull	DotPrudoct
174	RBN	QuickProp	Linear SigmoidAxon	-	ConscienceFull	DotPrudoct
175	RBN	DeltaBarDelta	Linear SigmoidAxon	-	ConscienceFull	DotPrudoct
176	RBN	QuickProp	Linear TanhAxon	-	ConscienceFull	DotPrudoct
177	RBN	Momentum	Linear TanhAxon	-	ConscienceFull	DotPrudoct
178	RBN	Step	Linear TanhAxon	-	ConscienceFull	DotPrudoct
179	RBN	ConjugateGradiant	Linear TanhAxon	-	ConscienceFull	DotPrudoct
180	RBN	DeltaBarDelta	Linear TanhAxon	-	ConscienceFull	DotPrudoct
181	RBN	Momentum	LinearAxon	-	ConscienceFull	DotPrudoct
182	RBN	Step	LinearAxon	-	ConscienceFull	DotPrudoct
183	RBN	ConjugateGradiant	LinearAxon	-	ConscienceFull	DotPrudoct

(EK-4'ün devamı)

Ağ Nu.	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu	Komşuluk	Karşılaştırma Kuralı	Metric
184	RBN	QuickProp	LinearAxon	-	ConscienceFull	DotPrudoct
185	RBN	DeltaBarDelta	LinearAxon	-	ConscienceFull	DotPrudoct
186	RBN	Momentum	Sigmoid Axon	-	ConscienceFull	DotPrudoct
187	RBN	Step	Sigmoid Axon	-	ConscienceFull	DotPrudoct
188	RBN	ConjugateGradiant	Sigmoid Axon	-	ConscienceFull	DotPrudoct
189	RBN	QuickProp	Sigmoid Axon	-	ConscienceFull	DotPrudoct
190	RBN	DeltaBarDelta	Sigmoid Axon	-	ConscienceFull	DotPrudoct
191	RBN	Momentum	Soft MaxAxon	-	ConscienceFull	DotPrudoct
192	RBN	Step	Soft MaxAxon	-	ConscienceFull	DotPrudoct
193	RBN	ConjugateGradiant	Soft MaxAxon	-	ConscienceFull	DotPrudoct
194	RBN	QuickProp	Soft MaxAxon	-	ConscienceFull	DotPrudoct
195	RBN	DeltaBarDelta	Soft MaxAxon	-	ConscienceFull	DotPrudoct
196	RBN	Momentum	TanhAxon	-	ConscienceFull	DotPrudoct
197	RBN	Step	TanhAxon	-	ConscienceFull	DotPrudoct
198	RBN	ConjugateGradiant	TanhAxon	-	ConscienceFull	DotPrudoct
199	RBN	QuickProp	TanhAxon	-	ConscienceFull	DotPrudoct
200	RBN	DeltaBarDelta	TanhAxon	-	ConscienceFull	DotPrudoct
201	RBN	Momentum	Axon	-	StandartFulll	DotPrudoct
202	RBN	Step	Axon	-	StandartFulll	DotPrudoct
203	RBN	ConjugateGradiant	Axon	-	StandartFulll	DotPrudoct
204	RBN	QuickProp	Axon	-	StandartFulll	DotPrudoct
205	RBN	DeltaBarDelta	Axon	-	StandartFulll	DotPrudoct
206	RBN	Momentum	BiasAxon	-	StandartFulll	DotPrudoct
207	RBN	Step	BiasAxon	-	StandartFulll	DotPrudoct
208	RBN	ConjugateGradiant	BiasAxon	-	StandartFulll	DotPrudoct
209	RBN	QuickProp	BiasAxon	-	StandartFulll	DotPrudoct
210	RBN	DeltaBarDelta	BiasAxon	-	StandartFulll	DotPrudoct
211	RBN	Momentum	Linear SigmoidAxon	-	StandartFulll	DotPrudoct
212	RBN	Step	Linear SigmoidAxon	-	StandartFulll	DotPrudoct
213	RBN	ConjugateGradiant	Linear SigmoidAxon	-	StandartFulll	DotPrudoct
214	RBN	QuickProp	Linear SigmoidAxon	-	StandartFulll	DotPrudoct
215	RBN	DeltaBarDelta	Linear SigmoidAxon	-	StandartFulll	DotPrudoct
216	RBN	Momentum	Linear TanhAxon	-	StandartFulll	DotPrudoct
217	RBN	Step	Linear TanhAxon	-	StandartFulll	DotPrudoct
218	RBN	ConjugateGradiant	Linear TanhAxon	-	StandartFulll	DotPrudoct
219	RBN	QuickProp	Linear TanhAxon	-	StandartFulll	DotPrudoct
220	RBN	DeltaBarDelta	Linear TanhAxon	-	StandartFulll	DotPrudoct
221	RBN	Momentum	LinearAxon	-	StandartFulll	DotPrudoct
222	RBN	Step	LinearAxon	-	StandartFulll	DotPrudoct
223	RBN	ConjugateGradiant	LinearAxon	-	StandartFulll	DotPrudoct
224	RBN	QuickProp	LinearAxon	-	StandartFulll	DotPrudoct
225	RBN	DeltaBarDelta	LinearAxon	-	StandartFulll	DotPrudoct
226	RBN	Momentum	Sigmoid Axon	-	StandartFulll	DotPrudoct
227	RBN	Step	Sigmoid Axon	-	StandartFulll	DotPrudoct
228	RBN	ConjugateGradiant	Sigmoid Axon	-	StandartFulll	DotPrudoct
229	RBN	QuickProp	Sigmoid Axon	-	StandartFulll	DotPrudoct
230	RBN	DeltaBarDelta	Sigmoid Axon	-	StandartFulll	DotPrudoct
231	RBN	Momentum	Soft MaxAxon	-	StandartFulll	DotPrudoct
232	RBN	Step	Soft MaxAxon	-	StandartFulll	DotPrudoct
233	RBN	ConjugateGradiant	Soft MaxAxon	-	StandartFulll	DotPrudoct
234	RBN	QuickProp	Soft MaxAxon	-	StandartFulll	DotPrudoct
235	RBN	DeltaBarDelta	Soft MaxAxon	-	StandartFulll	DotPrudoct
236	RBN	Momentum	TanhAxon	-	StandartFulll	DotPrudoct
237	RBN	Step	TanhAxon	-	StandartFulll	DotPrudoct
238	RBN	ConjugateGradiant	TanhAxon	-	StandartFulll	DotPrudoct
239	RBN	QuickProp	TanhAxon	-	StandartFulll	DotPrudoct
240	RBN	DeltaBarDelta	TanhAxon	-	StandartFulll	DotPrudoct
241	RBN	Momentum	Axon	-	ConscienceFull	Euclidian
242	RBN	Step	Axon	-	ConscienceFull	Euclidian
243	RBN	ConjugateGradiant	Axon	-	ConscienceFull	Euclidian
244	RBN	QuickProp	Axon	-	ConscienceFull	Euclidian

(EK-4'ün devamı)

Ağ Nu.	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu	Komşuluk	Karşılaştırma Kuralı	Metric
245	RBN	DeltaBarDelta	Axon	-	ConscienceFull	Euclidian
246	RBN	Momentum	BiasAxon	-	ConscienceFull	Euclidian
247	RBN	Step	BiasAxon	-	ConscienceFull	Euclidian
248	RBN	ConjugateGradiant	BiasAxon	-	ConscienceFull	Euclidian
249	RBN	QuickProp	BiasAxon	-	ConscienceFull	Euclidian
250	RBN	DeltaBarDelta	BiasAxon	-	ConscienceFull	Euclidian
251	RBN	Momentum	Linear SigmoidAxon	-	ConscienceFull	Euclidian
252	RBN	Step	Linear SigmoidAxon	-	ConscienceFull	Euclidian
253	RBN	ConjugateGradiant	Linear SigmoidAxon	-	ConscienceFull	Euclidian
254	RBN	QuickProp	Linear SigmoidAxon	-	ConscienceFull	Euclidian
255	RBN	DeltaBarDelta	Linear SigmoidAxon	-	ConscienceFull	Euclidian
256	RBN	Momentum	Linear TanhAxon	-	ConscienceFull	Euclidian
257	RBN	Step	Linear TanhAxon	-	ConscienceFull	Euclidian
258	RBN	ConjugateGradiant	Linear TanhAxon	-	ConscienceFull	Euclidian
259	RBN	QuickProp	Linear TanhAxon	-	ConscienceFull	Euclidian
260	RBN	DeltaBarDelta	Linear TanhAxon	-	ConscienceFull	Euclidian
261	RBN	Momentum	LinearAxon	-	ConscienceFull	Euclidian
262	RBN	Step	LinearAxon	-	ConscienceFull	Euclidian
263	RBN	ConjugateGradiant	LinearAxon	-	ConscienceFull	Euclidian
264	RBN	QuickProp	LinearAxon	-	ConscienceFull	Euclidian
265	RBN	DeltaBarDelta	LinearAxon	-	ConscienceFull	Euclidian
266	RBN	Momentum	Sigmoid Axon	-	ConscienceFull	Euclidian
267	RBN	Step	Sigmoid Axon	-	ConscienceFull	Euclidian
268	RBN	ConjugateGradiant	Sigmoid Axon	-	ConscienceFull	Euclidian
269	RBN	QuickProp	Sigmoid Axon	-	ConscienceFull	Euclidian
270	RBN	DeltaBarDelta	Sigmoid Axon	-	ConscienceFull	Euclidian
271	RBN	Momentum	Soft MaxAxon	-	ConscienceFull	Euclidian
272	RBN	Step	Soft MaxAxon	-	ConscienceFull	Euclidian
273	RBN	ConjugateGradiant	Soft MaxAxon	-	ConscienceFull	Euclidian
274	RBN	QuickProp	Soft MaxAxon	-	ConscienceFull	Euclidian
275	RBN	DeltaBarDelta	Soft MaxAxon	-	ConscienceFull	Euclidian
276	RBN	Momentum	TanhAxon	-	ConscienceFull	Euclidian
277	RBN	Step	TanhAxon	-	ConscienceFull	Euclidian
278	RBN	ConjugateGradiant	TanhAxon	-	ConscienceFull	Euclidian
279	RBN	QuickProp	TanhAxon	-	ConscienceFull	Euclidian
280	RBN	DeltaBarDelta	TanhAxon	-	ConscienceFull	Euclidian
281	RBN	Momentum	Axon	-	StandartFulll	Euclidian
282	RBN	Step	Axon	-	StandartFulll	Euclidian
283	RBN	ConjugateGradiant	Axon	-	StandartFulll	Euclidian
284	RBN	QuickProp	Axon	-	StandartFulll	Euclidian
285	RBN	DeltaBarDelta	Axon	-	StandartFulll	Euclidian
286	RBN	Momentum	BiasAxon	-	StandartFulll	Euclidian
287	RBN	Step	BiasAxon	-	StandartFulll	Euclidian
288	RBN	ConjugateGradiant	BiasAxon	-	StandartFulll	Euclidian
289	RBN	QuickProp	BiasAxon	-	StandartFulll	Euclidian
290	RBN	DeltaBarDelta	BiasAxon	-	StandartFulll	Euclidian
291	RBN	Momentum	Linear SigmoidAxon	-	StandartFulll	Euclidian
292	RBN	Step	Linear SigmoidAxon	-	StandartFulll	Euclidian
293	RBN	ConjugateGradiant	Linear SigmoidAxon	-	StandartFulll	Euclidian
294	RBN	QuickProp	Linear SigmoidAxon	-	StandartFulll	Euclidian
295	RBN	DeltaBarDelta	Linear SigmoidAxon	-	StandartFulll	Euclidian
296	RBN	Momentum	Linear TanhAxon	-	StandartFulll	Euclidian
297	RBN	Step	Linear TanhAxon	-	StandartFulll	Euclidian
298	RBN	ConjugateGradiant	Linear TanhAxon	-	StandartFulll	Euclidian
299	RBN	QuickProp	Linear TanhAxon	-	StandartFulll	Euclidian
300	RBN	DeltaBarDelta	Linear TanhAxon	-	StandartFulll	Euclidian
301	RBN	Momentum	LinearAxon	-	StandartFulll	Euclidian
302	RBN	Step	LinearAxon	-	StandartFulll	Euclidian
303	RBN	ConjugateGradiant	LinearAxon	-	StandartFulll	Euclidian
304	RBN	QuickProp	LinearAxon	-	StandartFulll	Euclidian
305	RBN	DeltaBarDelta	LinearAxon	-	StandartFulll	Euclidian

(EK-4'ün devamı)

Ağ Nu.	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu	Komşuluk	Karşılaştırma Kuralı	Metric
306	RBN	Momentum	Sigmoid Axon	-	StandartFulll	Euclidian
307	RBN	Step	Sigmoid Axon	-	StandartFulll	Euclidian
308	RBN	ConjugateGradiant	Sigmoid Axon	-	StandartFulll	Euclidian
309	RBN	QuickProp	Sigmoid Axon	-	StandartFulll	Euclidian
310	RBN	DeltaBarDelta	Sigmoid Axon	-	StandartFulll	Euclidian
311	RBN	Momentum	Soft MaxAxon	-	StandartFulll	Euclidian
312	RBN	Step	Soft MaxAxon	-	StandartFulll	Euclidian
313	RBN	ConjugateGradiant	Soft MaxAxon	-	StandartFulll	Euclidian
314	RBN	QuickProp	Soft MaxAxon	-	StandartFulll	Euclidian
315	RBN	DeltaBarDelta	Soft MaxAxon	-	StandartFulll	Euclidian
316	RBN	Momentum	TanhAxon	-	StandartFulll	Euclidian
317	RBN	Step	TanhAxon	-	StandartFulll	Euclidian
318	RBN	ConjugateGradiant	TanhAxon	-	StandartFulll	Euclidian
319	RBN	QuickProp	TanhAxon	-	StandartFulll	Euclidian
320	RBN	DeltaBarDelta	TanhAxon	-	StandartFulll	Euclidian
321	RBN	Momentum	Axon	-	ConscienceFull	BoxCar
322	RBN	Step	Axon	-	ConscienceFull	BoxCar
323	RBN	ConjugateGradiant	Axon	-	ConscienceFull	BoxCar
324	RBN	QuickProp	Axon	-	ConscienceFull	BoxCar
325	RBN	DeltaBarDelta	Axon	-	ConscienceFull	BoxCar
326	RBN	Momentum	BiasAxon	-	ConscienceFull	BoxCar
327	RBN	Step	BiasAxon	-	ConscienceFull	BoxCar
328	RBN	ConjugateGradiant	BiasAxon	-	ConscienceFull	BoxCar
329	RBN	QuickProp	BiasAxon	-	ConscienceFull	BoxCar
330	RBN	DeltaBarDelta	BiasAxon	-	ConscienceFull	BoxCar
331	RBN	Momentum	Linear SigmoidAxon	-	ConscienceFull	BoxCar
332	RBN	Step	Linear SigmoidAxon	-	ConscienceFull	BoxCar
333	RBN	ConjugateGradiant	Linear SigmoidAxon	-	ConscienceFull	BoxCar
334	RBN	QuickProp	Linear SigmoidAxon	-	ConscienceFull	BoxCar
335	RBN	DeltaBarDelta	Linear SigmoidAxon	-	ConscienceFull	BoxCar
336	RBN	Momentum	Linear TanhAxon	-	ConscienceFull	BoxCar
337	RBN	Step	Linear TanhAxon	-	ConscienceFull	BoxCar
338	RBN	ConjugateGradiant	Linear TanhAxon	-	ConscienceFull	BoxCar
339	RBN	QuickProp	Linear TanhAxon	-	ConscienceFull	BoxCar
340	RBN	DeltaBarDelta	Linear TanhAxon	-	ConscienceFull	BoxCar
341	RBN	Momentum	LinearAxon	-	ConscienceFull	BoxCar
342	RBN	Step	LinearAxon	-	ConscienceFull	BoxCar
343	RBN	ConjugateGradiant	LinearAxon	-	ConscienceFull	BoxCar
344	RBN	QuickProp	LinearAxon	-	ConscienceFull	BoxCar
345	RBN	DeltaBarDelta	LinearAxon	-	ConscienceFull	BoxCar
346	RBN	Momentum	Sigmoid Axon	-	ConscienceFull	BoxCar
347	RBN	Step	Sigmoid Axon	-	ConscienceFull	BoxCar
348	RBN	ConjugateGradiant	Sigmoid Axon	-	ConscienceFull	BoxCar
349	RBN	QuickProp	Sigmoid Axon	-	ConscienceFull	BoxCar
350	RBN	DeltaBarDelta	Sigmoid Axon	-	ConscienceFull	BoxCar
351	RBN	Momentum	Soft MaxAxon	-	ConscienceFull	BoxCar
352	RBN	Step	Soft MaxAxon	-	ConscienceFull	BoxCar
353	RBN	ConjugateGradiant	Soft MaxAxon	-	ConscienceFull	BoxCar
354	RBN	QuickProp	Soft MaxAxon	-	ConscienceFull	BoxCar
355	RBN	DeltaBarDelta	Soft MaxAxon	-	ConscienceFull	BoxCar
356	RBN	Momentum	TanhAxon	-	ConscienceFull	BoxCar
357	RBN	Step	TanhAxon	-	ConscienceFull	BoxCar
358	RBN	ConjugateGradiant	TanhAxon	-	ConscienceFull	BoxCar
359	RBN	QuickProp	TanhAxon	-	ConscienceFull	BoxCar
360	RBN	DeltaBarDelta	TanhAxon	-	ConscienceFull	BoxCar
361	RBN	Momentum	Axon	-	StandartFulll	BoxCar
362	RBN	Step	Axon	-	StandartFulll	BoxCar
363	RBN	ConjugateGradiant	Axon	-	StandartFulll	BoxCar
364	RBN	QuickProp	Axon	-	StandartFulll	BoxCar
365	RBN	DeltaBarDelta	Axon	-	StandartFulll	BoxCar
366	RBN	Momentum	BiasAxon	-	StandartFulll	BoxCar

(EK-4'ün devamı)

Ağ Nu.	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu	Komşuluk	Karşılaştırma Kuralı	Metric
367	RBN	Step	BiasAxon	-	StandartFulll	BoxCar
368	RBN	ConjugateGradiant	BiasAxon	-	StandartFulll	BoxCar
369	RBN	QuickProp	BiasAxon	-	StandartFulll	BoxCar
370	RBN	DeltaBarDelta	BiasAxon	-	StandartFulll	BoxCar
371	RBN	Momentum	Linear SigmoidAxon	-	StandartFulll	BoxCar
372	RBN	Step	Linear SigmoidAxon	-	StandartFulll	BoxCar
373	RBN	ConjugateGradiant	Linear SigmoidAxon	-	StandartFulll	BoxCar
374	RBN	QuickProp	Linear SigmoidAxon	-	StandartFulll	BoxCar
375	RBN	DeltaBarDelta	Linear SigmoidAxon	-	StandartFulll	BoxCar
376	RBN	Momentum	Linear TanhAxon	-	StandartFulll	BoxCar
377	RBN	Step	Linear TanhAxon	-	StandartFulll	BoxCar
378	RBN	ConjugateGradiant	Linear TanhAxon	-	StandartFulll	BoxCar
379	RBN	QuickProp	Linear TanhAxon	-	StandartFulll	BoxCar
380	RBN	DeltaBarDelta	Linear TanhAxon	-	StandartFulll	BoxCar
381	RBN	Momentum	LinearAxon	-	StandartFulll	BoxCar
382	RBN	Step	LinearAxon	-	StandartFulll	BoxCar
383	RBN	ConjugateGradiant	LinearAxon	-	StandartFulll	BoxCar
384	RBN	QuickProp	LinearAxon	-	StandartFulll	BoxCar
385	RBN	DeltaBarDelta	LinearAxon	-	StandartFulll	BoxCar
386	RBN	Momentum	Sigmoid Axon	-	StandartFulll	BoxCar
387	RBN	Step	Sigmoid Axon	-	StandartFulll	BoxCar
388	RBN	ConjugateGradiant	Sigmoid Axon	-	StandartFulll	BoxCar
389	RBN	QuickProp	Sigmoid Axon	-	StandartFulll	BoxCar
390	RBN	DeltaBarDelta	Sigmoid Axon	-	StandartFulll	BoxCar
391	RBN	Momentum	Soft MaxAxon	-	StandartFulll	BoxCar
392	RBN	Step	Soft MaxAxon	-	StandartFulll	BoxCar
393	RBN	ConjugateGradiant	Soft MaxAxon	-	StandartFulll	BoxCar
394	RBN	QuickProp	Soft MaxAxon	-	StandartFulll	BoxCar
395	RBN	DeltaBarDelta	Soft MaxAxon	-	StandartFulll	BoxCar
396	RBN	Momentum	TanhAxon	-	StandartFulll	BoxCar
397	RBN	Step	TanhAxon	-	StandartFulll	BoxCar
398	RBN	ConjugateGradiant	TanhAxon	-	StandartFulll	BoxCar
399	RBN	QuickProp	TanhAxon	-	StandartFulll	BoxCar
400	RBN	DeltaBarDelta	TanhAxon	-	StandartFulll	BoxCar

EK-5 Ağ Yapısına Göre Karşılaştırma Değerleri

Ağ Nu.	"r"	Sipariş Planı Yüzdesi	OptimumToplam Maliyetten Sapma Yüzdesi	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
1	0,98569	87,50000	0,468393371	ÇKA	Momentum	TanhAxon
2	0,88357	89,61538	0,261179935	ÇKA	Momentum	Sigmoid Axon
3	0,95251	86,34615	0,531299105	ÇKA	Momentum	Linear TanhAxon
4	0,83491	89,29487	0,392785012	ÇKA	Momentum	Linear SigmoidAxon
5	0,00000	38,14103	13,441214156	ÇKA	Momentum	Soft MaxAxon
6	0,75914	61,85897	3,485703447	ÇKA	Momentum	BiasAxon
7	0,00000	61,85897	3,485703447	ÇKA	Momentum	LinearAxon
8	0,73469	86,66667	0,503048567	ÇKA	Momentum	Axon
9	0,98700	88,46154	0,329848121	ÇKA	Step	TanhAxon
10	0,94554	87,50000	0,474177096	ÇKA	ConjugateGradiant	TanhAxon
11	0,98791	86,98718	0,451990693	ÇKA	QuickProp	TanhAxon
12	0,98936	87,37179	0,413045601	ÇKA	DeltaBarDelta	TanhAxon
13	0,83879	90,76923	0,242098517	ÇKA	Step	Sigmoid Axon
14	0,92259	90,76923	0,224556881	ÇKA	ConjugateGradiant	Sigmoid Axon
15	0,83449	91,02564	0,212258315	ÇKA	QuickProp	Sigmoid Axon
16	0,91146	90,44872	0,256259957	ÇKA	DeltaBarDelta	Sigmoid Axon
17	0,89033	88,14103	0,371585302	ÇKA	Step	Linear TanhAxon
18	0,93128	87,82051	0,411059786	ÇKA	ConjugateGradiant	Linear TanhAxon
19	0,95745	88,84615	0,332505552	ÇKA	QuickProp	Linear TanhAxon
20	0,94463	85,32051	0,597113576	ÇKA	DeltaBarDelta	Linear TanhAxon
21	0,79200	89,80769	0,290120887	ÇKA	Step	LinearSigmoidAxon
22	0,86527	89,35897	0,281252779	ÇKA	ConjugateGradiant	LinearSigmoidAxon
23	0,81802	90,83333	0,261503961	ÇKA	QuickProp	LinearSigmoidAxon
24	0,92192	88,39744	0,394930377	ÇKA	DeltaBarDelta	LinearSigmoidAxon
25	0,00000	61,85897	3,485703447	ÇKA	Step	BiasAxon
26	0,75914	91,08974	0,240719748	ÇKA	ConjugateGradiant	BiasAxon
27	0,00000	61,85897	3,485703447	ÇKA	QuickProp	BiasAxon
28	0,00000	61,85897	3,485703447	ÇKA	DeltaBarDelta	BiasAxon
29	0,00000	61,85897	3,485703447	ÇKA	Step	LinearAxon
30	0,75914	91,08974	0,240719748	ÇKA	ConjugateGradiant	LinearAxon
31	0,75914	91,08974	0,240719748	ÇKA	QuickProp	LinearAxon
32	0,75914	91,08974	0,240719748	ÇKA	DeltaBarDelta	LinearAxon
33	0,00000	38,14103	13,441214156	ÇKA	Step	SoftMaxAxon
34	0,00000	38,14103	13,441214156	ÇKA	ConjugateGradiant	SoftMaxAxon
35	0,00000	38,14103	13,441214156	ÇKA	QuickProp	SoftMaxAxon
36	0,00000	38,14103	13,441214156	ÇKA	DeltaBarDelta	SoftMaxAxon
37	0,73469	86,66667	0,503048567	ÇKA	Step	Axon
38	0,73469	86,66667	0,503048567	ÇKA	ConjugateGradiant	Axon
39	0,73469	86,66667	0,503048567	ÇKA	QuickProp	Axon
40	0,73469	86,66667	0,503048567	ÇKA	DeltaBarDelta	Axon
41	0,55503	87,62821	0,451463537	SOFM	Momentum	TanhAxon
42	0,81654	87,50000	0,403387690	SOFM	Momentum	TanhAxon
43	0,83793	87,24359	0,513227225	SOFM	Momentum	TanhAxon
44	0,59633	83,78205	0,821452904	SOFM	Step	TanhAxon
45	0,76224	83,78205	0,821452904	SOFM	Step	TanhAxon
46	0,68247	83,14103	0,962328533	SOFM	Step	TanhAxon
47	0,76572	87,30769	0,492506507	SOFM	ConjugateGradiant	TanhAxon
48	0,73433	85,96154	0,712025531	SOFM	ConjugateGradiant	TanhAxon
49	0,71568	86,34615	0,619766765	SOFM	ConjugateGradiant	TanhAxon
50	0,61834	75,12821	1,467386371	SOFM	QuickProp	TanhAxon
51	0,59523	74,80769	1,648269342	SOFM	QuickProp	TanhAxon
52	0,75193	86,98718	0,609656978	SOFM	QuickProp	TanhAxon
53	0,85902	87,43590	0,596772800	SOFM	DeltaBarDelta	TanhAxon
54	0,83262	88,65385	0,439812041	SOFM	DeltaBarDelta	TanhAxon
55	0,84038	87,88462	0,402429417	SOFM	DeltaBarDelta	TanhAxon

(EK-5'in devamı)

Ağ Nu.	"r"	Sipariş Planı Yüzdesi	OptimumToplam Maliyetten Sapma Yüzdesi	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
56	0,74268	87,75641	0,444281295	SOFM	Momentum	Sigmoid Axon
57	0,69728	85,76923	0,648215337	SOFM	Momentum	Sigmoid Axon
58	0,79000	89,80769	0,269969839	SOFM	Step	Sigmoid Axon
59	0,78678	89,87179	0,249984647	SOFM	ConjugateGradiant	Sigmoid Axon
60	0,80177	90,44872	0,236213223	SOFM	QuickProp	Sigmoid Axon
61	0,83215	90,00000	0,232767163	SOFM	DeltaBarDelta	Sigmoid Axon
62	0,65731	80,76923	1,163840006	SOFM	Momentum	Linear TanhAxon
63	0,59422	71,98718	1,840389716	SOFM	Step	Linear TanhAxon
64	0,72942	85,89744	0,602201959	SOFM	ConjugateGradiant	Linear TanhAxon
65	0,57052	72,11538	2,024275675	SOFM	QuickProp	Linear TanhAxon
66	0,77765	86,41026	0,597560176	SOFM	DeltaBarDelta	Linear TanhAxon
67	0,42341	62,62821	2,214838165	SOFM	Momentum	Linear SigmoidAxon
68	0,70588	85,76923	0,706374563	SOFM	Step	Linear SigmoidAxon
69	0,71451	86,92308	0,612787473	SOFM	ConjugateGradiant	Linear SigmoidAxon
70	0,66594	84,74359	0,746767038	SOFM	QuickProp	Linear SigmoidAxon
71	0,72710	85,83333	0,686370098	SOFM	DeltaBarDelta	Linear SigmoidAxon
72	0,00000	38,14103	13,441214156	SOFM	Momentum	Soft MaxAxon
73	0,00000	38,14103	13,441214156	SOFM	Step	Soft MaxAxon
74	0,00000	38,14103	13,441214156	SOFM	ConjugateGradiant	Soft MaxAxon
75	0,05755	38,14103	13,441214156	SOFM	QuickProp	Soft MaxAxon
76	0,00000	38,14103	13,441214156	SOFM	DeltaBarDelta	Soft MaxAxon
77	0,00000	69,67949	2,436855068	SOFM	Momentum	BiasAxon
78	0,00000	76,08974	1,630655002	SOFM	Step	BiasAxon
79	0,64244	76,08974	1,630655002	SOFM	ConjugateGradiant	BiasAxon
80	0,55365	73,46154	1,974933837	SOFM	QuickProp	BiasAxon
81	0,68577	84,10256	0,852597325	SOFM	DeltaBarDelta	BiasAxon
82	0,00000	71,21795	2,304376266	SOFM	Momentum	LinearAxon
83	0,61004	78,14103	1,399075592	SOFM	Step	LinearAxon
84	0,60421	81,73077	1,045395474	SOFM	ConjugateGradiant	LinearAxon
85	0,54264	63,46154	2,397561043	SOFM	QuickProp	LinearAxon
86	0,53789	61,85897	3,485703447	SOFM	DeltaBarDelta	LinearAxon
87	0,74613	82,94872	0,797368359	SOFM	Momentum	Axon
88	0,60273	73,52564	1,847665127	SOFM	Step	Axon
89	0,75283	85,38462	0,601682028	SOFM	ConjugateGradiant	Axon
90	0,67142	85,38462	0,601682028	SOFM	QuickProp	Axon
91	0,67530	86,92308	0,461525396	SOFM	DeltaBarDelta	Axon
92	0,00000	52,50000	5,109287211	SOFM	Step	Sigmoid Axon
93	0,78113	89,61538	0,310159399	SOFM	ConjugateGradiant	Sigmoid Axon
94	0,78183	90,19231	0,266805263	SOFM	QuickProp	Sigmoid Axon
95	0,83432	90,12821	0,226531443	SOFM	DeltaBarDelta	Sigmoid Axon
96	0,75461	84,87179	0,745083123	SOFM	Momentum	Linear TanhAxon
97	0,05132	67,37179	2,410415936	SOFM	Step	Linear TanhAxon
98	0,00000	40,19231	10,373373715	SOFM	ConjugateGradiant	Linear TanhAxon
99	0,53305	71,28205	2,317905147	SOFM	QuickProp	Linear TanhAxon
100	0,77774	86,02564	0,726437745	SOFM	DeltaBarDelta	Linear TanhAxon
101	0,66801	82,62821	1,027208372	SOFM	Momentum	Linear SigmoidAxon
102	0,70950	86,60256	0,645884197	SOFM	Step	Linear SigmoidAxon
103	-0,01656	62,30769	3,449019088	SOFM	ConjugateGradiant	Linear SigmoidAxon
104	0,55659	79,67949	1,689786125	SOFM	QuickProp	Linear SigmoidAxon
105	0,61809	82,43590	1,049178040	SOFM	DeltaBarDelta	Linear SigmoidAxon
106	-0,00449	38,14103	13,441214156	SOFM	Momentum	Soft MaxAxon
107	0,01384	38,14103	13,441214156	SOFM	Step	Soft MaxAxon
108	0,01775	38,14103	13,441214156	SOFM	ConjugateGradiant	Soft MaxAxon
109	-0,00449	38,14103	13,441214156	SOFM	QuickProp	Soft MaxAxon
110	-0,00045	38,14103	13,441214156	SOFM	DeltaBarDelta	Soft MaxAxon

(EK-5'in devamı)

Ağ Nu.	"r"	Sipariş Planı Yüzdesi	OptimumToplam Maliyetten Sapma Yüzdesi	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
111	-	69,80769	2,323490291	SOFM	Momentum	BiasAxon
112	-	42,50000	8,037143007	SOFM	Step	BiasAxon
113	0,66301	83,20513	0,885987181	SOFM	ConjugateGradiant	BiasAxon
114	0,57623	74,48718	1,912475462	SOFM	QuickProp	BiasAxon
115	0,69960	83,52564	0,842718637	SOFM	DeltaBarDelta	BiasAxon
116	0,00000	70,83333	2,321848258	SOFM	Momentum	LinearAxon
117	0,62620	80,12821	1,284419246	SOFM	Step	LinearAxon
118	0,66333	83,91026	0,877234188	SOFM	ConjugateGradiant	LinearAxon
119	0,62976	78,20513	1,339182631	SOFM	QuickProp	LinearAxon
120	0,70129	85,25641	0,761891316	SOFM	DeltaBarDelta	LinearAxon
121	0,68034	86,98718	0,491626755	SOFM	Momentum	Axon
122	0,68098	85,44872	0,584256575	SOFM	Step	Axon
123	0,68236	86,41026	0,548175554	SOFM	ConjugateGradiant	Axon
124	0,67831	86,34615	0,524974670	SOFM	QuickProp	Axon
125	0,68919	86,34615	0,535885643	SOFM	DeltaBarDelta	Axon
126	0,82810	90,70513	0,216408445	SOFM	Momentum	Sigmoid Axon
127	0,78246	90,06410	0,240251258	SOFM	Step	Sigmoid Axon
128	0,81850	90,57692	0,205060346	SOFM	ConjugateGradiant	Sigmoid Axon
129	0,79023	89,29487	0,282952533	SOFM	QuickProp	Sigmoid Axon
130	0,86516	90,06410	0,203872533	SOFM	DeltaBarDelta	Sigmoid Axon
131	0,73548	81,98718	0,999924047	SOFM	Momentum	Linear TanhAxon
132	0,66762	76,73077	1,430513983	SOFM	Step	Linear TanhAxon
133	0,02144	56,28205	5,285633201	SOFM	ConjugateGradiant	Linear TanhAxon
134	0,60043	72,11538	2,260395992	SOFM	QuickProp	Linear TanhAxon
135	0,81511	87,43590	0,518054220	SOFM	DeltaBarDelta	Linear TanhAxon
136	0,62639	82,24359	1,034121494	SOFM	Momentum	Linear SigmoidAxon
137	0,63007	81,28205	1,179765007	SOFM	Step	Linear SigmoidAxon
138	0,12387	57,88462	3,945078844	SOFM	ConjugateGradiant	Linear SigmoidAxon
139	0,54294	78,84615	1,306773231	SOFM	QuickProp	Linear SigmoidAxon
140	0,69370	83,39744	0,799775578	SOFM	DeltaBarDelta	Linear SigmoidAxon
141	-0,00449	38,14103	13,441214156	SOFM	Momentum	Soft MaxAxon
142	0,00399	38,14103	13,441214156	SOFM	Step	Soft MaxAxon
143	0,01466	38,14103	13,441214156	SOFM	ConjugateGradiant	Soft MaxAxon
144	-0,00449	38,14103	13,441214156	SOFM	QuickProp	Soft MaxAxon
145	-0,00449	38,14103	13,441214156	SOFM	DeltaBarDelta	Soft MaxAxon
146	0,00000	71,98718	2,197480905	SOFM	Momentum	BiasAxon
147	0,59250	73,97436	2,102882840	SOFM	Step	BiasAxon
148	0,67026	83,71795	0,898343883	SOFM	ConjugateGradiant	BiasAxon
149	0,53821	70,83333	2,346118497	SOFM	QuickProp	BiasAxon
150	0,70437	84,29487	0,752506083	SOFM	DeltaBarDelta	BiasAxon
151	0,00000	72,88462	2,033642094	SOFM	Momentum	LinearAxon
152	0,63719	79,48718	1,264730426	SOFM	Step	LinearAxon
153	0,67650	83,26923	0,836775965	SOFM	ConjugateGradiant	LinearAxon
154	0,60244	76,85897	1,625725816	SOFM	QuickProp	LinearAxon
155	0,00000	61,85897	13,441214156	SOFM	DeltaBarDelta	LinearAxon
156	0,68096	87,17949	0,461768445	SOFM	Momentum	Axon
157	0,68096	87,17949	0,461768445	SOFM	Step	Axon
158	0,67763	86,34615	0,583572957	SOFM	ConjugateGradiant	Axon
159	0,68703	85,83333	0,582178420	SOFM	QuickProp	Axon
160	0,69444	86,53846	0,501614052	SOFM	DeltaBarDelta	Axon
161	0,76698	90,96154	0,243946856	RBN	Momentum	Axon
162	0,76672	90,89744	0,256500565	RBN	Step	Axon
163	0,75649	90,83333	0,243822360	RBN	ConjugateGradiant	Axon
164	0,77034	91,15385	0,241416040	RBN	QuickProp	Axon
165	0,77075	91,15385	0,247992744	RBN	DeltaBarDelta	Axon

(EK-5'in devamı)

Ağ Nu.	"r"	Sipariş Planı Yüzdesi	OptimumToplam Maliyetten Sapma Yüzdesi	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
166	-	66,47436	2,806184893	RBN	Momentum	BiasAxon
167	0,64270	76,66667	1,450354399	RBN	Step	BiasAxon
168	0,60512	80,32051	1,052286439	RBN	ConjugateGradiant	BiasAxon
169	0,43066	66,92308	2,746030556	RBN	QuickProp	BiasAxon
170	0,74021	89,48718	0,342974246	RBN	DeltaBarDelta	BiasAxon
171	0,02319	42,43590	8,283388783	RBN	Momentum	Linear SigmoidAxon
172	0,04655	54,42308	7,401179089	RBN	Step	Linear SigmoidAxon
173	0,09599	60,44872	3,278347646	RBN	ConjugateGradiant	Linear SigmoidAxon
174	0,25400	61,66667	2,993727350	RBN	QuickProp	Linear SigmoidAxon
175	0,00707	43,91026	5,071381763	RBN	DeltaBarDelta	Linear SigmoidAxon
176	0,62466	65,57692	2,469403389	RBN	QuickProp	Linear TanhAxon
177	0,81065	90,70513	0,210864619	RBN	Momentum	Linear TanhAxon
178	0,57447	61,85897	3,485703447	RBN	Step	Linear TanhAxon
179	0,66807	84,55128	0,721529251	RBN	ConjugateGradiant	Linear TanhAxon
180	0,80565	90,96154	0,187286631	RBN	DeltaBarDelta	Linear TanhAxon
181	0,00000	88,65385	0,419826065	RBN	Momentum	LinearAxon
182	0,65543	75,96154	1,595025416	RBN	Step	LinearAxon
183	0,67725	85,51282	0,727599815	RBN	ConjugateGradiant	LinearAxon
184	0,58746	90,57692	0,281873446	RBN	QuickProp	LinearAxon
185	0,74854	63,84615	2,801654798	RBN	DeltaBarDelta	LinearAxon
186	0,26114	63,84615	2,801654798	RBN	Momentum	Sigmoid Axon
187	0,25467	62,56410	3,265178058	RBN	Step	Sigmoid Axon
188	0,06887	62,37179	3,304800209	RBN	ConjugateGradiant	Sigmoid Axon
189	0,31511	62,69231	3,245550378	RBN	QuickProp	Sigmoid Axon
190	0,81444	91,60256	0,190026032	RBN	DeltaBarDelta	Sigmoid Axon
191	0,04744	38,14103	13,441214156	RBN	Momentum	Soft MaxAxon
192	-	38,14103	13,441214156	RBN	Step	Soft MaxAxon
193	-	38,14103	13,441214156	RBN	ConjugateGradiant	Soft MaxAxon
194	0,04980	38,14103	13,441214156	RBN	QuickProp	Soft MaxAxon
195	-	38,14103	13,441214156	RBN	DeltaBarDelta	Soft MaxAxon
196	0,63770	74,55128	1,672304659	RBN	Momentum	TanhAxon
197	0,58251	70,12821	2,450870409	RBN	Step	TanhAxon
198	0,24098	64,10256	2,990775140	RBN	ConjugateGradiant	TanhAxon
199	0,59002	69,48718	2,102047934	RBN	QuickProp	TanhAxon
200	0,78893	91,08974	0,197210117	RBN	DeltaBarDelta	TanhAxon
201	0,76780	91,02564	0,245329078	RBN	Momentum	Axon
202	0,77254	90,96154	0,201595974	RBN	Step	Axon
203	0,75434	90,70513	0,313292054	RBN	ConjugateGradiant	Axon
204	0,77418	90,44872	0,218751014	RBN	QuickProp	Axon
205	0,76911	90,57692	0,246306568	RBN	DeltaBarDelta	Axon
206	0,84488	69,16667	2,449375076	RBN	Momentum	BiasAxon
207	0,63382	75,00000	1,684294473	RBN	Step	BiasAxon
208	0,69380	87,24359	0,445020659	RBN	ConjugateGradiant	BiasAxon
209	0,62574	69,03846	2,412469688	RBN	QuickProp	BiasAxon
210	0,73474	90,12821	0,275033999	RBN	DeltaBarDelta	BiasAxon
211	0,41977	44,93590	3,960787832	RBN	Momentum	Linear SigmoidAxon
212	0,05175	47,88462	2,930157889	RBN	Step	Linear SigmoidAxon
213	0,48358	72,94872	2,063787290	RBN	ConjugateGradiant	Linear SigmoidAxon
214	-	54,67949	4,103090257	RBN	QuickProp	Linear SigmoidAxon
215	0,03321	48,01282	4,912639716	RBN	DeltaBarDelta	Linear SigmoidAxon
216	0,48402	70,06410	2,281227259	RBN	Momentum	Linear TanhAxon
217	0,64939	70,00000	1,929438541	RBN	Step	Linear TanhAxon
218	0,70834	87,24359	0,558990670	RBN	ConjugateGradiant	Linear TanhAxon
219	0,57360	65,83333	2,990316904	RBN	QuickProp	Linear TanhAxon
220	0,80726	91,41026	0,175894432	RBN	DeltaBarDelta	Linear TanhAxon

(EK-5'in devamı)

Ağ Nu.	"r"	Sipariş Planı Yüzdesi	OptimumToplam Maliyetten Sapma Yüzdesi	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
221	0,00000	67,88462	2,650741044	RBN	Momentum	LinearAxon
222	0,57017	67,50000	2,719579220	RBN	Step	LinearAxon
223	0,68330	87,75641	0,592546485	RBN	ConjugateGradiant	LinearAxon
224	0,40267	62,88462	3,233960532	RBN	QuickProp	LinearAxon
225	0,00000	89,23077	0,407058016	RBN	DeltaBarDelta	LinearAxon
226	0,44820	66,08974	2,856870163	RBN	Momentum	Sigmoid Axon
227	0,45376	62,37179	3,304800209	RBN	Step	Sigmoid Axon
228	0,08725	62,37179	3,304800209	RBN	ConjugateGradiant	Sigmoid Axon
229	0,42828	62,56410	3,283839644	RBN	QuickProp	Sigmoid Axon
230	0,16936	61,85897	3,485703447	RBN	DeltaBarDelta	Sigmoid Axon
231	0,05580	38,14103	13,441214156	RBN	Momentum	Soft MaxAxon
232	0,06377	38,14103	13,441214156	RBN	Step	Soft MaxAxon
233	0,03766	38,14103	13,441214156	RBN	ConjugateGradiant	Soft MaxAxon
234	0,00788	38,14103	13,441214156	RBN	QuickProp	Soft MaxAxon
235	-	38,14103	13,441214156	RBN	DeltaBarDelta	Soft MaxAxon
236	0,66420	79,16667	1,301164082	RBN	Momentum	TanhAxon
237	0,64605	69,48718	1,984125778	RBN	Step	TanhAxon
238	0,71077	86,47436	0,522677382	RBN	ConjugateGradiant	TanhAxon
239	0,56616	71,98718	1,877594131	RBN	QuickProp	TanhAxon
240	0,79798	91,47436	0,210973967	RBN	DeltaBarDelta	TanhAxon
241	0,76878	91,08974	0,229415517	RBN	Momentum	Axon
242	0,76889	90,25641	0,258572467	RBN	Step	Axon
243	0,76145	90,44872	0,245178267	RBN	ConjugateGradiant	Axon
244	0,77070	90,76923	0,232715385	RBN	QuickProp	Axon
245	0,77448	90,51282	0,229152527	RBN	DeltaBarDelta	Axon
246	0,00000	65,38462	3,001347152	RBN	Momentum	BiasAxon
247	0,62814	70,06410	2,204238631	RBN	Step	BiasAxon
248	0,60499	80,38462	1,110320464	RBN	ConjugateGradiant	BiasAxon
249	0,62492	65,12821	3,042214591	RBN	QuickProp	BiasAxon
250	0,64847	81,92308	1,005880806	RBN	DeltaBarDelta	BiasAxon
251	0,20649	59,93590	3,314690694	RBN	Momentum	Linear SigmoidAxon
252	0,36907	68,58974	2,470466626	RBN	Step	Linear SigmoidAxon
253	0,02026	61,85897	3,485703447	RBN	ConjugateGradiant	Linear SigmoidAxon
254	0,16595	51,15385	2,670094924	RBN	QuickProp	Linear SigmoidAxon
255	0,69690	84,10256	0,872766938	RBN	DeltaBarDelta	Linear SigmoidAxon
256	0,62467	74,87179	1,841114638	RBN	Momentum	Linear TanhAxon
257	0,61136	73,97436	1,920362296	RBN	Step	Linear TanhAxon
258	0,71570	87,37179	0,515362884	RBN	ConjugateGradiant	Linear TanhAxon
259	0,53206	65,89744	2,603379000	RBN	QuickProp	Linear TanhAxon
260	0,41484	82,50000	0,926460079	RBN	DeltaBarDelta	Linear TanhAxon
261	0,50505	73,65385	1,718752857	RBN	Momentum	LinearAxon
262	0,60208	64,42308	3,110989903	RBN	Step	LinearAxon
263	0,01168	49,29487	3,630349692	RBN	ConjugateGradiant	LinearAxon
264	0,05484	66,02564	2,813508970	RBN	QuickProp	LinearAxon
265	0,39371	78,46154	1,231797877	RBN	DeltaBarDelta	LinearAxon
266	0,48812	80,25641	1,057393750	RBN	Momentum	Sigmoid Axon
267	0,84488	63,71795	3,185727880	RBN	Step	Sigmoid Axon
268	0,15858	61,85897	3,485703447	RBN	ConjugateGradiant	Sigmoid Axon
269	0,48895	64,03846	3,168496968	RBN	QuickProp	Sigmoid Axon
270	0,86417	90,51282	0,259323111	RBN	DeltaBarDelta	Sigmoid Axon
271	-	38,14103	13,441214156	RBN	Momentum	Soft MaxAxon
272	-	38,14103	13,441214156	RBN	Step	Soft MaxAxon
273	-	46,21795	13,622117394	RBN	ConjugateGradiant	Soft MaxAxon
274	0,00309	38,14103	13,441214156	RBN	QuickProp	Soft MaxAxon
275	-	38,14103	13,441214156	RBN	DeltaBarDelta	Soft MaxAxon

(EK-5'in devamı)

Ağ Nu.	"r"	Sipariş Planı Yüzdesi	OptimumToplam Maliyetten Sapma Yüzdesi	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
276	0,63312	74,74359	1,824424280	RBN	Momentum	TanhAxon
277	0,63312	67,69231	2,232867749	RBN	Step	TanhAxon
278	0,65185	83,91026	0,855877768	RBN	ConjugateGradiant	TanhAxon
279	0,56301	66,98718	2,636492487	RBN	QuickProp	TanhAxon
280	0,55505	82,88462	0,821710441	RBN	DeltaBarDelta	TanhAxon
281	0,79720	89,74359	0,234990063	RBN	Momentum	Axon
282	0,77760	90,32051	0,239274032	RBN	Step	Axon
283	0,75447	89,74359	0,272081210	RBN	ConjugateGradiant	Axon
284	0,76553	90,83333	0,236610585	RBN	QuickProp	Axon
285	0,76693	90,51282	0,247635284	RBN	DeltaBarDelta	Axon
286	-	68,58974	2,122547161	RBN	Momentum	BiasAxon
287	0,64953	66,92308	2,814222909	RBN	Step	BiasAxon
288	0,00000	83,52564	0,851032283	RBN	ConjugateGradiant	BiasAxon
289	0,64892	64,42308	3,124637066	RBN	QuickProp	BiasAxon
290	0,59883	77,94872	1,261326282	RBN	DeltaBarDelta	BiasAxon
291	-	50,06410	3,511126308	RBN	Momentum	Linear SigmoidAxon
292	0,11389	53,14103	2,576814084	RBN	Step	Linear SigmoidAxon
293	0,17468	78,39744	1,309093058	RBN	ConjugateGradiant	Linear SigmoidAxon
294	0,53029	55,19231	7,701828590	RBN	QuickProp	Linear SigmoidAxon
295	0,08179	83,97436	0,979381225	RBN	DeltaBarDelta	Linear SigmoidAxon
296	0,68600	70,44872	1,986953548	RBN	Momentum	Linear TanhAxon
297	0,60538	67,62821	2,337204156	RBN	Step	Linear TanhAxon
298	0,59437	52,94872	5,052987995	RBN	ConjugateGradiant	Linear TanhAxon
299	0,72942	66,02564	2,831231997	RBN	QuickProp	Linear TanhAxon
300	0,56139	82,11538	0,953981491	RBN	DeltaBarDelta	Linear TanhAxon
301	0,56139	67,82051	2,487603327	RBN	Momentum	LinearAxon
302	0,00000	64,42308	3,135069249	RBN	Step	LinearAxon
303	0,62005	64,42308	3,135069249	RBN	ConjugateGradiant	LinearAxon
304	0,64067	83,91026	0,784032237	RBN	QuickProp	LinearAxon
305	0,44228	64,35897	3,128020164	RBN	DeltaBarDelta	LinearAxon
306	0,00000	75,51282	1,455546422	RBN	Momentum	Sigmoid Axon
307	0,60362	79,61538	1,236761086	RBN	Step	Sigmoid Axon
308	0,47162	62,30769	3,316311820	RBN	ConjugateGradiant	Sigmoid Axon
309	0,03845	63,26923	3,245991243	RBN	QuickProp	Sigmoid Axon
310	0,46282	90,44872	0,217058155	RBN	DeltaBarDelta	Sigmoid Axon
311	0,82054	38,14103	13,441214156	RBN	Momentum	Soft MaxAxon
312	0,00000	38,14103	13,441214156	RBN	Step	Soft MaxAxon
313	0,00000	46,21795	13,622117394	RBN	ConjugateGradiant	Soft MaxAxon
314	0,41676	38,14103	13,441214156	RBN	QuickProp	Soft MaxAxon
315	0,00000	38,14103	13,441214156	RBN	DeltaBarDelta	Soft MaxAxon
316	0,79088	46,21795	13,622117394	RBN	Momentum	TanhAxon
317	0,76318	51,73077	7,065899528	RBN	Step	TanhAxon
318	0,73943	54,16667	3,895291857	RBN	ConjugateGradiant	TanhAxon
319	0,60355	58,52564	2,878007272	RBN	QuickProp	TanhAxon
320	0,62934	54,16667	4,803590979	RBN	DeltaBarDelta	TanhAxon
321	0,65665	49,80769	9,143466122	RBN	Momentum	Axon
322	0,64245	51,98718	2,137937026	RBN	Step	Axon
323	0,12104	49,80769	7,638579986	RBN	ConjugateGradiant	Axon
324	0,64706	54,16667	4,803590979	RBN	QuickProp	Axon
325	0,66272	54,16667	4,803590979	RBN	DeltaBarDelta	Axon
326	0,65041	54,42308	4,172299255	RBN	Momentum	BiasAxon
327	0,59850	52,94872	5,052987995	RBN	Step	BiasAxon
328	0,61705	50,57692	7,139492939	RBN	ConjugateGradiant	BiasAxon
329	0,60361	52,37179	6,589537797	RBN	QuickProp	BiasAxon
330	0,65174	56,85897	4,184885996	RBN	DeltaBarDelta	BiasAxon

(EK-4'ün devamı)

Ağ Nu.	"r"	Sipariş Planı Yüzdesi	OptimumToplam Maliyetten Sapma Yüzdesi	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
331	0,49184	60,19231	3,020939981	RBN	Momentum	Linear SigmoidAxon
332	0,06065	49,29487	7,341206464	RBN	Step	Linear SigmoidAxon
333	0,48228	60,44872	3,038584509	RBN	ConjugateGradiant	Linear SigmoidAxon
334	0,30262	57,37179	3,950715349	RBN	QuickProp	Linear SigmoidAxon
335	0,47538	57,37179	3,950715349	RBN	DeltaBarDelta	Linear SigmoidAxon
336	0,60870	53,65385	3,046855193	RBN	Momentum	Linear TanhAxon
337	0,61155	51,60256	7,506142039	RBN	Step	Linear TanhAxon
338	0,63171	53,14103	5,984440129	RBN	ConjugateGradiant	Linear TanhAxon
339	0,62117	52,37179	6,163659173	RBN	QuickProp	Linear TanhAxon
340	0,66001	53,01282	5,940527428	RBN	DeltaBarDelta	Linear TanhAxon
341	-	53,01282	5,940527428	RBN	Momentum	LinearAxon
342	0,62114	52,50000	6,149295285	RBN	Step	LinearAxon
343	0,61326	51,47436	6,125592678	RBN	ConjugateGradiant	LinearAxon
344	0,61818	55,32051	2,734130381	RBN	QuickProp	LinearAxon
345	0,63580	50,57692	7,139492939	RBN	DeltaBarDelta	LinearAxon
346	0,54698	50,57692	7,139492939	RBN	Momentum	Sigmoid Axon
347	0,51365	60,57692	3,169049445	RBN	Step	Sigmoid Axon
348	0,48558	60,57692	3,092011187	RBN	ConjugateGradiant	Sigmoid Axon
349	0,49144	59,93590	3,314690694	RBN	QuickProp	Sigmoid Axon
350	0,55139	58,78205	3,178022753	RBN	DeltaBarDelta	Sigmoid Axon
351	0,03085	38,14103	13,441214156	RBN	Momentum	Soft MaxAxon
352	0,00052	38,14103	13,441214156	RBN	Step	Soft MaxAxon
353	0,05344	46,21795	13,622117394	RBN	ConjugateGradiant	Soft MaxAxon
354	0,58251	38,14103	13,441214156	RBN	QuickProp	Soft MaxAxon
355	0,05302	38,14103	13,441214156	RBN	DeltaBarDelta	Soft MaxAxon
356	0,64397	50,06410	6,173978908	RBN	Momentum	TanhAxon
357	0,66871	53,01282	7,366884691	RBN	Step	TanhAxon
358	0,50758	53,65385	4,086863267	RBN	ConjugateGradiant	TanhAxon
359	0,64989	78,14103	1,335235396	RBN	QuickProp	TanhAxon
360	0,71198	53,01282	5,940527428	RBN	DeltaBarDelta	TanhAxon
361	0,64329	53,65385	4,086863267	RBN	Momentum	Axon
362	0,64887	52,37179	6,163659173	RBN	Step	Axon
363	0,64740	54,42308	4,172299255	RBN	ConjugateGradiant	Axon
364	0,65096	53,65385	4,086863267	RBN	QuickProp	Axon
365	0,65304	53,14103	5,984440129	RBN	DeltaBarDelta	Axon
366	0,64220	55,57692	3,792935439	RBN	Momentum	BiasAxon
367	0,64232	77,56410	1,368543131	RBN	Step	BiasAxon
368	0,61832	52,62821	5,124936719	RBN	ConjugateGradiant	BiasAxon
369	0,59929	50,19231	7,378310538	RBN	QuickProp	BiasAxon
370	0,64567	52,37179	6,163659173	RBN	DeltaBarDelta	BiasAxon
371	0,18209	55,96154	4,225158246	RBN	Momentum	Linear SigmoidAxon
372	0,23056	51,98718	7,461560659	RBN	Step	Linear SigmoidAxon
373	0,00525	46,21795	13,622117394	RBN	ConjugateGradiant	Linear SigmoidAxon
374	0,18014	52,75641	6,573840047	RBN	QuickProp	Linear SigmoidAxon
375	0,11451	46,79487	5,776931262	RBN	DeltaBarDelta	Linear SigmoidAxon
376	0,67014	50,57692	7,139492939	RBN	Momentum	Linear TanhAxon
377	0,67014	52,75641	5,902649415	RBN	Step	Linear TanhAxon
378	0,63034	51,34615	7,467141850	RBN	ConjugateGradiant	Linear TanhAxon
379	0,62961	53,91026	4,125863456	RBN	QuickProp	Linear TanhAxon
380	0,65490	55,96154	4,137430910	RBN	DeltaBarDelta	Linear TanhAxon
381	0,64139	53,91026	5,067835886	RBN	Momentum	LinearAxon
382	0,63615	53,65385	4,086863267	RBN	Step	LinearAxon
383	0,64331	53,52564	4,124844168	RBN	ConjugateGradiant	LinearAxon
384	0,62788	54,42308	4,835141877	RBN	QuickProp	LinearAxon
385	0,64438	53,39744	6,348824082	RBN	DeltaBarDelta	LinearAxon

(EK-4'ün devamı)

Ağ Nu.	"r"	Sipariş Planı Yüzdesi	OptimumToplam Maliyetten Sapma Yüzdesi	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
386	0,19613	57,50000	3,017990610	RBN	Momentum	Sigmoid Axon
387	0,40227	55,32051	3,165333900	RBN	Step	Sigmoid Axon
388	0,34454	62,37179	3,304800209	RBN	ConjugateGradiant	Sigmoid Axon
389	0,35227	56,85897	3,141154633	RBN	QuickProp	Sigmoid Axon
390	0,45673	52,17949	5,027853473	RBN	DeltaBarDelta	Sigmoid Axon
391	0,07114	38,14103	13,441214156	RBN	Momentum	Soft MaxAxon
392	0,11158	38,14103	13,441214156	RBN	Step	Soft MaxAxon
393	0,03501	46,21795	13,622117394	RBN	ConjugateGradiant	Soft MaxAxon
394	0,12467	38,14103	13,441214156	RBN	QuickProp	Soft MaxAxon
395	0,01277	38,14103	13,441214156	RBN	DeltaBarDelta	Soft MaxAxon
396	0,65193	52,37179	5,075585518	RBN	Momentum	TanhAxon
397	0,65603	55,32051	2,734130381	RBN	Step	TanhAxon
398	0,62484	50,19231	7,378310538	RBN	ConjugateGradiant	TanhAxon
399	0,63726	55,19231	2,935379463	RBN	QuickProp	TanhAxon
400	0,69436	79,74359	1,196328452	RBN	DeltaBarDelta	TanhAxon

EK-6 Korelasyon Katsayısının 0,8'den Yüksek olan Ağların Listesi

Sıra Numarası	Ağ Numarası	Korelâsyon Katsayısı "r"	Ağ Tipi	Öğrenme Kuralı	Transfer Fonksiyonu
1	12	0,98936	ÇKA	DeltaBarDelta	TanhAxon
2	11	0,98791	ÇKA	QuickProp	TanhAxon
3	9	0,98700	ÇKA	Step	TanhAxon
4	1	0,98569	ÇKA	Momentum	TanhAxon
5	19	0,95745	ÇKA	QuickProp	Linear TanhAxon
6	3	0,95251	ÇKA	Momentum	Linear TanhAxon
7	10	0,94554	ÇKA	ConjugateGradiant	TanhAxon
8	20	0,94463	ÇKA	DeltaBarDelta	Linear TanhAxon
9	18	0,93128	ÇKA	ConjugateGradiant	Linear TanhAxon
10	14	0,92259	ÇKA	ConjugateGradiant	Sigmoid Axon
11	24	0,92192	ÇKA	DeltaBarDelta	LinearSigmoidAxon
12	16	0,91146	ÇKA	DeltaBarDelta	Sigmoid Axon
13	17	0,89033	ÇKA	Step	Linear TanhAxon
14	2	0,88357	ÇKA	Momentum	Sigmoid Axon
15	22	0,86527	ÇKA	ConjugateGradiant	LinearSigmoidAxon
16	130	0,86516	SOFM	DeltaBarDelta	Sigmoid Axon
17	270	0,86417	RBN	DeltaBarDelta	Sigmoid Axon
18	53	0,85902	SOFM	DeltaBarDelta	TanhAxon
19	206	0,84488	RBN	Momentum	BiasAxon
20	267	0,84488	RBN	Step	Sigmoid Axon
21	55	0,84038	SOFM	DeltaBarDelta	TanhAxon
22	13	0,83879	ÇKA	Step	Sigmoid Axon
23	43	0,83793	SOFM	Momentum	TanhAxon
24	4	0,83491	ÇKA	Momentum	Linear SigmoidAxon
25	15	0,83449	ÇKA	QuickProp	Sigmoid Axon
26	95	0,83432	SOFM	DeltaBarDelta	Sigmoid Axon
27	54	0,83262	SOFM	DeltaBarDelta	TanhAxon
28	61	0,83215	SOFM	DeltaBarDelta	Sigmoid Axon
29	126	0,82810	SOFM	Momentum	Sigmoid Axon
30	311	0,82054	RBN	Momentum	Soft MaxAxon
31	128	0,81850	SOFM	ConjugateGradiant	Sigmoid Axon
32	23	0,81802	ÇKA	QuickProp	LinearSigmoidAxon
33	42	0,81654	SOFM	Momentum	TanhAxon
34	135	0,81511	SOFM	DeltaBarDelta	Linear TanhAxon
35	190	0,81444	RBN	DeltaBarDelta	Sigmoid Axon
36	177	0,81065	RBN	Momentum	Linear TanhAxon
37	220	0,80726	RBN	DeltaBarDelta	Linear TanhAxon
38	180	0,80565	RBN	DeltaBarDelta	Linear TanhAxon
39	60	0,80177	SOFM	QuickProp	Sigmoid Axon

KAYNAKLAR

1. Wagner H.M., Whitin T., 1958, Dynamic version of economic lot size model, **Management Science, 5**:89-96,
2. Anderson, D. ve McNeil, G., 1992, Artificial neural networks technology, Kaman Sciences Corporation , New York, 87.
3. Anil K.J., Mao J., Mohiuddin K.M., 1996, Artificial neural network: a tutorial, Michigan State University, **IEEE Computer Society, 96**: 31-44.
4. Michie D., Spiegelhalter D.J., Taylor C.C., 1994, Machine learning, neural and statistical classification, **Journal of the American Statistical Association, 84**:102,223.
5. Lotffi K.Gaafar, M.Hisham Choueiki, 2000, A neural network model for solving the lot-sizing problem, **Omega, 28**:175-184.
6. Goren H.G., Tunali S., Jans R., 2008, A review of applications of genetic algorithms in lot sizing, **Springer Science Business Media, 21**:575-590.
7. Zangwill,W.J., 1966, Deterministic multi product , multi facility production and inventory model, **Management Science, 15(9):** 486-507.
8. Zangwill,W.J. 1966, Deterministic multi product , multi period production scheduling model with backlogging, **Management Science, 13(1):** 105-119.
9. Maes, J., McClain, J., Van Wassenhove , L.N., 1991, Multi level capaciated lot sizing complexity and L.P. based heuristic, **European Journal of Operational Research, 53:** 131-148.
10. Aarts EHL, M.F.Reijnhoudt, Stehouwer HP, Wessels J., 1998, A novel decomposition dpproach for on-line lot-sizing, **European Journal of Operational Research, 122:** 339-353.
11. Pedroso J.P., Kubo J., 2005, Hybrid tabu search for lot sizing problems, **Springer-Verlag Berlin Heidelberg, 3636:** 66-67.
12. Megala N., Jawahar N. 2005, Genetic algorithm and hopfield neural network for a dynamic lot sizing problem, **Springer-Verlag London Limited, 27:** 1178-1191.
13. Radzi N.H.M., Haron H., Jahori T.I.T, 2000, Lot sizing using neural network approach, 2nd IMT-GT Regional Conference on Mathematics, Statistic and Applications, Universiti Sains Malaysia, 13-15, 4-8, June, Penang.

14. McCulloch S.W., Pitts, H.W., 1943, A logical calculus of the ideas immanent in neural nets, **Bulletin of Mathematical Biophysics, 5:**115-133.
15. Yurtoğlu H., 2005, Yapay sinir ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği, Ekonomik Modeller Ve Stratejik Araştırmalar Genel Müdürlüğü, DPT Uzmanlık Tezi, Ankara, 113s.
16. Yıldız Ö. 2006, Döviz Kurlarında Yapay Sinir Ağlarının Kullanımı, Osman Gazi Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Eskişehir, 198s.
17. Kohonen T., 1988, Self-organization and associative memory, **Second Edition, Springer-Verlag, 43**: 241-243.
18. Hopfield J. J., 1982, Neural networks and physical systems with emergent collective computational abilities, **Proceedings of the National Academy of Sciences, 79**.
19. Ackley D.H., Hinton G.E., Sejnowski, T.J., 1985, A learning algorithm for boltzmann machines, **Cognitive Science, 9:** 318-364.
20. Myers, J.H., Alpert, M.I., 1968, Determinant buying attribute "Meaning and measurement", **Marketing, 32(10):** 13-20.
21. Saaty, T., 1980, The analytic hierarchy process, **McGraw-Hill International Book Company, 36(2):**244.
22. Saaty, T., 2000, The analytic hierarchy and analytic network processes, MCDM XV-th International Conference, Ankara, Temmuz 10-14
23. Tam, M.C.Y., Tummala, V.M.R., 2001, An application of the ahp in vendor selection of a telecommunications system, **The International Journal of Management Science, 29(2):** 171-182.
24. Sanchez, S.D., Trıantaphyllou, E., Webster, D.N., Lıao T.W., 2001, A Study of The Total Inventory Cost as a Function of The Reorder Interval of Some Lot Sizing Techniques Used in MRP Systems, **Computers Industrial Engineering Journal, 40**:101,116.
25. Şenyiğit, E., 2001, Malzeme ihtiyaç planlama sistemlerinde (MRP) en çok kullanılan sipariş büyüklüğü belirleme yöntemleri ile yeni bir sezgisel algoritmanın karşılaştırılması, Çukurova Üniversitesi, Yüksek Lisans Tezi, Adana, 276s.
26. Heuvel W., Wagelmansa A., 2007, Worst case analysis for a general class of on-line lot-sizing heuristics, **Econometric Institute Report, 46:**3,12.

27. Şenyiğit E., Yıldırım F., 2002, Sipariş Büyüklüğü Belirleme Yöntemleri İle Yeni Bir Sezgisel Algoritmanın Karşılaştırılması, Çukurova Ünv., 2,7.
28. Tersine Richard J., 1994, Render Barry, Inventory Management, Prentice Hall, New Jersey.
29. ACAR N., 1999, Malzeme İhtiyaç Planlaması, Milli Prodüktivite Merkezi Yayınları, Ankara.
30. Axsater S., 2006, Inventry Control,Springer International Series, 306s,
31. Özyörük, B. ve Erol, S., 2000, Parti büyüklüğü problemleri ile ilgili literatür araştırması, **Süleyman Demirel Ünv. İktisadi ve İdari Bilimler Fakültesi, 5:**105,119.
32. Anil K.J., Mao J., Mohiuddin K.M., 1996, Artificial Neural Network: A Tutorial, **IBM Almaden Research Center, 96:**31,44.
33. Kröse B.,Smagt P., 1996, An Introduction to Neural Networks, The University Of Amsterdam, Netherlands, 135s.
34. Anderson D., McNeill G., 1992, Artificial Neural Network Technology, Kaman Sciences Corporation, New York, 87s.
35. Mandic D., P. ,Chambers J.A.,2001, Recurrent Neural Networks For Prediction - Learning Algorithms, Architectures And Stability, John Wiley & Sons Ltd, 281s.
36. Demuth H, Beale M., 2004, Neural Network Toolbox For Use with MATLAB, Natic, 846s.
37. NeroSolitions V.4.23 Help.
38. Saraç T., 2004, Yapay Sinir Ağları, Seminer Projesi, Gazi Üniversitesi, Ankara, 75s.
39. Trigerio ,W.W., Thomas, L.J. and Mc Clain J.G., 1989, Capacitated Lot Sizing With Setup Times, Mng.Sci. 35,3.
40. Lawrence S, Giles C. L., 2000, Fong Sandiway:Natural Language Grammatical Inference with Recurrent Neural Networks, **IEEE Transactions on Knowledge and Data Engineering, 12:**126,140.
41. Özşahin M., 2009, Türkiye otomotiv sektörünün kendini örgütleyen haritalar ile finansal analizi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Adana, 138s.

42. Dağdeviren M., Akay D., Kurt M. 2004, İş Değerlendirme Sürecinde Analitik Hiyerarşi Prosesi Ve Uygulaması, G**azi Üniv. Müh. Mim. Fak. Dergisi, 19:** 131,138.

43. Saaty, T., 2004, The analytic hierarchy and analytic network processes for the measurement of intangible criteria and for decision-making, Katz Graduate School of Business University of Pittsburgh, Pittsburgh, 407s.

44. Tam, M.C.Y., Tummala, V.M.R., 2001, An Application of The AHP in Vendor Selection of a Telecommunications System, **The International Journal of Management Science, 29(2):** 171,182.

45. Kuruüzüm, A. & Atsan, N., 2001, Analitik hiyerarşi yöntemi ve işletmecilik Alanındaki uygulamaları, **Akdeniz İİBF Dergisi, 1:** 83,105.

46. Eroğlu E. Lorcu F., 2007, Veri zarflama analitik hiyerarşi prosesi ile sayisal karar verme, **İ.Ü. İşletme Fakültesi İşletme Dergisi, 36(2):**30, 53.

47. Saaty T.L. & Vargas, L.F., 1991, Prediction, Projection and Forecasting, Kluwer Academic, Boston.

48. Tulunay, Y., 2006, İşletme Matematiği, Nobel Yayınevi, Dördüncü Baskı, İstanbul.

49. Aguaron, J. & Jimenez M.M., 2003, The geometric consistency index: Approximated thresholds, **European Journal of Operational Research,** 137,145.

50. Saaty T.L., 1982, The Analytic Hierarchy Process: Planning, Priority Setting, Resource Allocation, McGraw-Hill Comp., U.S.A.

51. Timor, M., 2001, Yöneylem Araştırması ve İşletmecilik Uygulamaları, İÜ İşletme Fakültesi Yayını, İstanbul.

52. Holger R. M., Graeme C. D., 1999, Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, Elsevier.

ÖZ GEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı: Uğur ATİCİ
Uyruğu: Türkiye (TC)
Doğum Tarihi ve Yeri: 1 Şubat 1980, Artvin
Medeni Durumu: Evli
Tel: +90 5448606155
Fax: -
email: uguratici@yahoo.com
Yazışma Adresi: Erenkey Mah. 2HİBM Loj 52-1 38050 Melikgazi/KAYSERİ

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	EÜ Fen Bilimler Enstitüsü	2011
Lisans	Balıkesir Unv. M. M.F End. Bl.	2001
Lise	Atatürk Lisesi, Ankara	1997

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2010- Halen	2 HİBM K.lığı	Ürt. Pl. Grp. A.
2005- 2010	2 HİBM K.lığı	Ürt. Pl. Ks. Şf.
2004–2005	4T Bilgi İşlem Teknolojileri	Uygulama Proje Yöneticisi
2003–2004	4T Bilgi İşlem Teknolojileri	İş Analisti

YABANCI DİL

İngilizce

YAYINLAR