

**UKUROVA NİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

Kübra Nur MARAŞLIOĞLU

**BİR HALI FİRMASINDA CAĞ DEĞİŞİM SÜRELERİNİN
YAPAY SİNİR AĞI YAKLAŞIMI İLE TAHMİNLENMESİ**

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

ADANA, 2021

ÖZ

YÜKSEK LİSANS TEZİ

BİR HALI FİRMASINDA CAĞ DEĞİŞİM SÜRELERİNİN YAPAY SİNİR AĞI YAKLAŞIMI İLE TAHMİNLENMESİ

Kübra Nur MARAŞLIOĞLU

ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

Danışman: : Doç. Dr. Yusuf KUVVETLİ
Yıl: 2021, Sayfa: 129
Jüri: : Doç. Dr. Yusuf KUVVETLİ
: Prof. Dr. Pınar DURU BAYKAL
: Dr. Öğr. Üyesi Mehmet ŞAHİN

Bu çalışmada çağ değişim süreleri tahmin edilerek halı üretim sürecinin öngörülmesini sağlamak ve üretim planlama ile satış birimi için önemli bir bilgi kaynağı sunmak amaçlanmıştır. Dokuma biriminde bulunan çağ değişim sürecinde, değişim yapılan tezgâhlarda üretim tamamen durduğundan dolayı bu değişim sürecinde yaşanacak herhangi bir aksaklık tüm halı üretimini etkileyerek teslim zamanında gecikmelere yol açabilir. Bu yüzden çağ değişim sürelerini doğru tahmin etmek üretici için çok önemlidir. Çağ değişim süreleri tahmini için çeşitli yapay sinir ağ yöntemleri denenmiş en iyi tahmin yöntemini bulmak ve klasik yöntemlere göre çok daha seri ve yüksek doğrulukta üretim optimizasyonunun sağlanması için yeni bir hibrit model elde edilmiştir. Çalışma sırasında dokuma tezgâhlarının özellikleri doğrultusunda düzenlenen tarak numarası, tezgâh eni, renk, tezgâh bobin sayısı ve değişen bobin sayısı olmak üzere 5 girdi ve çağ değişim sürelerini kapsayan 1 çıktıdan oluşan 308 duruş verisi kullanılmış olup bu veriler; farklı yapay sinir ağ modelleri ile tahmin edilmiştir. Yöntemlerin performanslarının kıyaslanmasında ortalama mutlak yüzde hata (MAPE) değeri kullanılarak en başarılı tahmin modeline karar verilmiştir. En iyi modellere ait test seti MAPE değerleri; MLP modeli için %24, GRNN modeli için %30, çoklu regresyon modeli için %33 ve hibritleştirilmiş sinir ağı modeli için %18 göz önüne alındığında hibrit yapay sinir ağ modelinin diğer modellere göre daha başarılı olduğu görülmektedir.

Anahtar Kelimeler: Yapay sinir ağı, Hibrit sinir ağları, Çok katmanlı algılayıcılar, Genelleştirilmiş regresyon sinir ağları, Çağ değişimi tahminleme

ABSTRACT

MSc. THESIS

PREDICTION OF CREEL CHANGE DELAYS IN CARPET PRODUCTION VIA ARTIFICIAL NEURAL NETWORK APPROACH

Kübra Nur MARAŞLIOĞLU

ÇUKUROVA UNIVERSITY
INSTITUTE OF NATURAL AND APPLIED SCIENCES
DEPARTMENT OF INDUSTRIAL ENGINEERING

Supervisor : Assoc. Prof. Dr. Yusuf KUVVETLİ
Year: 2021, Page: 129
Jury : Assoc. Prof. Dr. Yusuf KUVVETLİ
: Prof. Dr. Pınar DURU BAYKAL
: Asst. Prof. Dr. Mehmet ŞAHİN

In this study, it is aimed to predict the carpet production process and to provide an important source of information for the production planning and sales unit by predicting creel change times. A decision model is proposed for the weaving unit involved in the carpet production to predict the creel change process; thereby, prevent possible delays and deliver the customer demands on time. This process is selected because production stalls in the changes made entirely, and that process disruptions will be experienced in delays on due dates. Various artificial neural network methods have been tried to predict the creel change delays, and a new hybrid model has been obtained to find the best prediction method and to provide much more rapid and high accuracy production optimization compared to classical methods. The dataset having 308 test samples constitutes five input parameters: comb number, color, bench width, loom coil number, and changing coil number, and one output parameter as the creel change delays. These four models are compared to each other using the mean absolute percentage error (MAPE) value to find the most accurate prediction model. It is aimed to select the best structures by evaluating the different structures of each model using the grid-search approach. According to best found results for all models, the MAPE values of the test dataset were calculated as 24%, 30%, 33%, and 18%, in MLP, GRNN, linear regression and hybrid model respectively. Consequently, the hybrid model is determined as the most accurate method when compared to other models.

Keywords: Artificial neural network, Hybrid neural networks, Multi layer perceptron, Generalized regression neural networks, Creel change prediction

GENİŞLETİLMİŞ ÖZET

Teknolojinin sürekli gelişmeye de devam etmesi işletmeler arası rekabeti beraberinde getirmektedir. Tüm firmaların artan rekabet koşullarında öne çıkabilmeleri için müşterilerin taleplerini tam zamanında ve eksiksiz olarak karşılayabilmeleri gerekmektedir. Bu durum olası gecikmeleri önlemek amacıyla firmaları tahminler yapmaya zorlamıştır. Tahminleme için çeşitli yöntemler kullanılmaktadır. Doğrusal problemler için klasik istatistiksel yöntemler yeterli olmakla birlikte, çoğu iş problemi doğrusal değildir ve klasik yöntemler yetersizdir. Son yıllarda yaygın ve başarılı kullanıma sahip, yapay zekânın alt dallarından biri olan yapay sinir ağları (YSA) bu noktada farklı uygulamalardaki başarısıyla tatmin edici duruma sahiptir. Farklı alanlarda yapılan çalışmalarda uygulanan YSA ile elde edilen tahminleme sonuçlarının istatistiksel yöntemlere göre çok daha başarılı olduğu tespit edilmiştir. Ayrıca yapay sinir ağlarının girdiler ile çıktılar arasındaki karmaşık doğrusal olmayan ilişkilendirmeleri ortaya çıkarmasındaki başarısı bu çalışmada da kullanılmasında etkili olmuştur.

Halı üretimi dokuma prosesinde çağ değişim sürelerini doğru tahmin etmek buna göre planlama yapmak üretim akışının aksamaması için kritik öneme sahiptir. Çünkü dokuma biriminde yer alan çağ değişim sürecinde, değişim yapılan tezgâhlarda üretim tamamen durmaktadır. Bu değişim sürecinde yaşanacak herhangi bir aksaklık tüm halı üretimini etkileyerek teslim zamanında gecikmelere yol açabilir.

Bu çalışmada; halı üretimi dokuma biriminde yer alan çağ değişim sürelerinin en iyi tahmin yöntemi ile tahmin edilerek, sürecin öngörülmesini sağlamak ve üretim planlama ile satış birimine önemli bir bilgi kaynağı sunmak ve oluşabilecek gecikmeleri en aza indirmek amaçlanmıştır. Böylece üretim yapılan tezgâhta ortalama duruş süreleri tahmin edilerek üretim akışı doğru bir şekilde planlanabilecek ve zamanında tamamlanan ürünler termini gecikmeden teslim edilerek müşteri memnuniyeti sağlanabilecektir. Ayrıca, çağ değişim sürelerinin tahminlemesine yönelik doğrudan halı üretimi ile ilişkilendirilecek YSA çalışmasına

rastlanılmamış olup çalışma bu yönü ile önem arz etmekte ve çalışmanın literatüre katkı sağlayacağı düşünülmektedir.

Bu amaçla Gaziantep’ te bulunan bir halı firmasından elde edilen bilgiler doğrultusunda 308 veri kullanılmış olup tarak numarası, tezgâh eni, renk, tezgâh bobin sayısı ve değişen bobin sayısı olmak üzere 5 girdi ve çağ değişim sürelerini kapsayan 1 çıktıdan oluşan çeşitli YSA modelleri oluşturulmuştur.

Çalışmada YSA modellerinin oluşturulmasında ve performanslarının kıyaslanmasında, farklı YSA modelleri kullanılmıştır. YSA modellerinden MLP ve GRNN ağlarına ek olarak klasik istatistik yöntem olan çoklu regresyon analizi de kullanılmış ve bu üç modelden elde edilen performans değerlerini iyileştirmek için hibrit bir tahminleme yöntemi önerilmiştir. Oluşturulan sinir ağ modelleri için farklı sayıda nöron ve gizli katman, farklı oranlarda eğitim, doğrulama ve test dağılımı, farklı öğrenme ve momentum katsayıları, radyal değerler ile denemeler yapılmıştır. Çalışmada performans ölçütü olarak ortalama mutlak yüzde hata (MAPE) dikkate alınmakla beraber hata kareleri ortalaması (MSE) ve regresyon R değerleri de kaydedilmiştir.

Performans analizinde, tüm yöntemlerin aynı eğitim, doğrulama ve test verileriyle çalışılması sağlanmıştır. Test verileri modellerin daha önce eğitimde kullanmadığı veriler olduğu için performans analizinde kullanılarak en iyi sonuca ulaşmaya çalışılmıştır. Yapılan denemeler sonucunda, seçilen yöntemler için en iyi sonuç veren modellere ait test seti MAPE değerleri; MLP modeli için %24, GRNN modeli için %30, çoklu regresyon modeli için %33 ve hibritleştirilmiş sinir ağı modeli için %18 olduğu gözlemlenmiştir. Sonuç olarak hibritleştirilmiş YSA yönteminin sonuçlarının diğer yöntemler ile karşılaştırıldığında gerçek değerlere çok daha yakın olduğu ve bu nedenle hibritleştirilmiş YSA'nın daha başarılı görüldüğü tespit edilmiş ve çağ değişim sürelerini tahmin etmede güvenilir bir yöntem olduğu sonucuna varılmıştır.

TEŞEKKÜR

Tez çalışma sürecimde danışmanlığı ile beni yönlendiren, fikirleriyle yol gösteren, vaktini ve ilgisini esirgemeyen değerli danışman hocam Doç. Dr. Yusuf KUVVETLİ'ye sonsuz minnet ve teşekkürlerimi sunarım.

Çalışmama değerli katkılarını sunan Sayın jüri üyeleri Prof. Dr. Pınar DURU BAYKAL ve Dr. Öğr. Üyesi Mehmet ŞAHİN 'e sonsuz teşekkürlerimi sunarım.

Hayatın her alanında maddi ve manevi desteklerini esirgemeyen, her konuda bana güvenip destek olan aileme teşekkürlerimi sunuyorum.

Çalışmamda maddi ve manevi destek olan arkadaşlarım Emine ÇOT ve Selma GÜLYEŞİL' e teşekkürlerimi sunarım.

İÇİNDEKİLER

SAYFA

ÖZ	I
ABSTRACT.....	II
GENİŞLETİLMİŞ ÖZET	III
TEŞEKKÜR.....	V
İÇİNDEKİLER	VI
ÇİZELGELER DİZİNİ	X
ŞEKİLLER DİZİNİ	XII
SİMGELER VE KISALTMALAR.....	XIV
1. GİRİŞ	1
1.1. Halının Yapısı	3
1.1.1. Çağ	6
1.2. Tahminleme	9
1.2.1. Tahmin Yöntemleri	10
1.3.Regresyon Analizi	13
1.3.1. Basit Doğrusal Regresyon Analizi.....	13
1.3.2. Çoklu Doğrusal Regresyon Analizi	15
1.3.3. Doğrusal Olmayan Regresyon Analizi	15
1.4. Yapay Sinir Ağları	16
1.4.1. Yapay Sinir Ağlarının Tanımı	16
1.4.2. Yapay Sinir Ağlarının Tarihçesi.....	17
1.4.3. Yapay Sinir Ağlarının Kullanım Alanları.....	21
1.4.4.Yapay Sinir Ağlarının Genel Özellikleri	22
1.4.5. Yapay Sinir Ağlarının Avantaj ve Dezavantajları	23
1.4.5.1. Yapay Sinir Ağlarının Avantajları.....	24
1.4.5.2. Yapay Sinir Ağlarının Dezavantajları.....	25
1.4.6. Yapay Sinir Ağlarının Yapısı.....	25
1.4.6.1. Biyolojik sinir ağları.....	25

1.4.6.2. Yapay Sinir Ağları.....	27
1.5. Yapay Sinir Ağ Modelleri.....	36
1.5.1. Basit Algılayıcı Model (Perceptron).....	36
1.5.2. Çok Katmanlı Algılayıcılar (Multi Layer Perceptron).....	36
1.5.3. Öğrenme Vektör Nicelendirmesi Ağı	38
1.5.4. Som Ağı (Self-Organizing Map)	38
1.5.5. Uyarlanabilir Rezonans (ART) Ağı.....	39
1.5.6. Hopfield Ağı	39
1.5.7. Elman Ağı.....	40
1.5.8. Radyal Tabanlı Yapay Sinir Ağları (RBF)	41
1.5.9. Genelleştirilmiş Regresyon Yapay Sinir Ağları (GRNN).....	42
1.5.10. Hibrit Yapay Sinir Ağları	43
1.6. Yapay Sinir Ağlarında Öğrenme.....	44
1.6.1. Danışmanlı Öğrenme	44
1.6.2. Danışmansız Öğrenme	45
1.6.3. Takviyeli Öğrenme	45
1.7. Yapay Sinir Ağlarında Öğrenme Kuralları	45
1.7.1. Hebb Kuralı.....	46
1.7.2. Hopfield Kuralı	46
1.7.3. Delta Kuralı.....	46
1.7.4. Kohonen Kuralı.....	46
1.7.5. Dereceli Azaltma (Gradient Descent) Kuralı	47
1.8. Yapay Sinir Ağının Tasarımı	47
1.8.1. Eğitim ve Test Setlerinin Belirlenmesi	48
1.8.2. Normalizasyon	48
1.8.3. Gizli Katman Sayısı ve Nöron Sayısının Belirlenmesi	49
1.8.4. Öğrenme Algoritmasının Seçimi.....	50
1.8.5. Yapay Sinir Ağı Parametrelerinin Belirlenmesi.....	50
1.8.6. Yapay Sinir Ağlarının Eğitimi ve Testi.....	51

1.8.7. Eğitimin Sonlandırılması.....	52
1.8.8. Performans Ölçütünün Belirlenmesi	52
1.9 Problemin Tanımı	53
1.10. Çalışmanın Amacı.....	54
1.11. Çalışmanın Önemi	55
1.12. Çalışmanın Adımları ve Organizasyonu	55
1.12.1. Çalışmanın Adımları	55
1.12.2. Çalışmanın Organizasyonu	56
2. LİTERATÜR TARAMASI	57
2.1. Yapay Sinir Ağları ile Tahminleme için Literatür Taraması	57
2.2. YSA ile Süre Tahminleme için Literatür Taraması	62
2.3. Tekstil ve Halı Sektöründe Tahminleme için Literatür Taraması.....	66
2.4. Önceki Çalışmaların Değerlendirilmesi.....	69
3. MATERYAL VE METOT	71
3.1. Materyal.....	71
3.1.1. Dokuma.....	71
3.1.2. Verilerin Düzenlenmesi	74
3.2. Metot.....	75
3.2.1. Yapay Sinir Ağı Modellerinin Seçimi.....	76
3.2.1.1. Verilerin Normalizasyonu	76
3.2.1.2. Yapay Sinir Ağının Yapısı	77
3.2.2. MLP Ağı.....	77
3.2.2.1. MLP Ağı Parametre Optimizasyonu.....	77
3.2.2.2. Performans Ölçütü ile Kıyaslama	79
3.2.3. GRNN Ağı.....	80
3.2.4. Çoklu Regresyon Analizi	80
3.2.5. Hibrit Model.....	80
4. BULGULAR.....	83
4.1. Veri Analizi.....	83

4.2.MLP Sonuçları.....	87
4.3.GRNN Sonuçları.....	93
4.4.Çoklu Regresyon Analizi Sonuçları	96
4.5.Hibrit Model Sonuçları	99
4.6.Sonuçların Karşılaştırılması.....	105
5. SONUÇLAR VE ÖNERİLER.....	109
5.2.Sonuçlar.....	109
5.3.Öneriler.....	111
KAYNAKLAR	113
ÖZGEÇMİŞ	125
EKLER.....	127
EK 1. Tasarlanan YSA modeli.....	129

ÇİZELGELER DİZİNİ

SAYFA

Çizelge 1.1. Van de Wiele makine modelleri	3
Çizelge 1.2. Biyolojik sinir sistemi ile YSA'nın yapısal benzerlikleri	28
Çizelge 1.3. İstatistiksel yöntemlerle yapay sinir ağlarının benzerlikleri	28
Çizelge 1.4. Toplama fonksiyonu örnekleri.....	31
Çizelge 1.5. Yapay sinir ağları performans ölçütleri	53
Çizelge 3.1. Özet veri seti	72
Çizelge 3.2. Duruşların sınıflandırılması	74
Çizelge 3.3. Çalışmada kullanılan YSA parametreleri	79
Çizelge 4.1. Örnek veri setinin normalize değerleri	85
Çizelge 4.2. Çağ değişimi değişkenleri için korelasyon matrisi	86
Çizelge 4.3. MLP modeline ait en iyi 10 deneme	88
Çizelge 4.4. MLP540 sinir ağı parametreleri	89
Çizelge 4.5. MLP540 performans ölçütleri.....	93
Çizelge 4.6. GRNN modeline ait en iyi 10 deneme	94
Çizelge 4.7. GRNN1 performans ölçütleri.....	96
Çizelge 4.8. Eğitim veri seti için çoklu regresyon analizi katsayıları	97
Çizelge 4.9. Çoklu regresyon analizi performans ölçütleri.....	99
Çizelge 4.10. Hibrit modeline ait en iyi 10 deneme.....	100
Çizelge 4.11. HİBMLP7 sinir ağı parametreleri	101
Çizelge 4.12. HİBMLP7 performans ölçütleri.....	105
Çizelge 4.13. En iyi modellerin karşılaştırılması.....	105
Çizelge 4.14. Gerçek çıktı ve tahmin değerlerin karşılaştırılması	108



ŞEKİLLER DİZİNİ

SAYFA

Şekil 1.1. Küresel halı ihracat dağılımı.....	2
Şekil 1.2. Yüz yüze ile dokunmuş halının görünüşü	3
Şekil 1.3. Makine halısı dokuma kesiti	4
Şekil 1.4. Hav yüzeyi	5
Şekil 1.5. Halı dokuma makinesi	6
Şekil 1.6. Çağ bölümü	7
Şekil 1.7. Tahminlemenin kullanıldığı yerler	9
Şekil 1.8. Tahminlemede kullanılan yöntemlerin sınıflandırılması	12
Şekil 1.9. Sinir sisteminin blok diyagram gösterimi	26
Şekil 1.10. Biyolojik sinir hücresi ve bileşenleri	27
Şekil 1.11. YSA mimarisinin blok diyagram gösterimi	29
Şekil 1.12. Yapay sinir hücresinin yapısı	29
Şekil 1.13. Sigmoid tipli fonksiyon	32
Şekil 1.14. Doğrusal fonksiyon.....	33
Şekil 1.15.Adım (eşik) fonksiyonu	34
Şekil 1.16. Hiperbolik tanjant fonksiyonu	35
Şekil 1.17. Sinüs fonksiyonu	35
Şekil 1.18. Çok katmanlı algılayıcı ağının yapısı	37
Şekil 1.19. Hopfield ağı	40
Şekil 1.20. Elman ağ yapısı.....	41
Şekil 1.21. Radyal tabanlı yapay sinir ağları (RBF)	41
Şekil 1.22. Genelleştirilmiş regresyon yapay sinir ağları (GRNN).....	43
Şekil 3.1. Dokuma birimi iş akış şeması	73
Şekil 3.2. Çalışmada kullanılan MLP ağ yapısı	78
Şekil 3.3. Çalışmada kullanılan hibrit sinir ağ yapısı.....	81
Şekil 4.1. Değişkenlere ait histogram grafikleri.....	84
Şekil 4.2. MLP540 modeli ağ yapısı.....	89

Şekil 4.3. MLP540 MSE grafiği	90
Şekil 4.4. MLP540 modelinin her veri grubu için R grafikleri	91
Şekil 4.5. Çağ değişim süreleri için MLP540 tahminleri ile gerçek değerler arasındaki karşılaştırma	92
Şekil 4.6. GRNN1 ağ yapısı	94
Şekil 4.7. GRNN1 modelinin her veri grubu için R grafikleri	95
Şekil 4.8. Çoklu regresyon analizinin veri seti için R grafiği	98
Şekil 4.9. HİBMLP7 modeli ağ yapısı	101
Şekil 4.10. HİBMLP7 MSE grafiği	102
Şekil 4.11. HİBMLP7 modelinin her veri grubu için R grafikleri	103
Şekil 4.12. Çağ değişim süreleri için HİBMLP7 tahminleri ile gerçek değerler arasındaki karşılaştırma	104
Şekil 4.13. Çağ değişim süreleri için çalışmada kullanılan model tahminleri ile gerçek değerler arasındaki karşılaştırma	106

SİMGELER VE KISALTMALAR

ADALINE	: Adaptive Linear Neuron
ANFIS	: Ağ Tabanlı Bulanık Çıkarım Sistemi
ANN	: Artificial Neural Network
ANOVA	: Varyans Analizi
AR	: Otoregresif Model
ARIMA	: Bütünleştirilmiş Otoregresif Hareketli Ortalama Modeli
ART	: Uyarlanabilir Rezonans Ağı
GRNN	: Genelleştirilmiş Regresyon Yapay Sinir Ağları
GRNN1	: GRNN Ağı İçin En Başarılı Model
HİBMLP7	: Hibrit Yapay Sinir Ağı İçin En Başarılı Model
kNN	: K-En Yakın Komşu Algoritması
LVQ	: Öğrenme Vektör Nicelendirme Ağı
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Hata Yüzdesi
MLP	: Çok Katmanlı Algılayıcı
MLP540	: MLP Ağı İçin En Başarılı Model
MPE	: Ortalama Yüzde Hata
MSE	: Hata Kareleri Ortalaması
MSPE	: Ortalama Yüzde Hata Kareleri
PNN	: Olasılıksal Sinir Ağları
R	: Regresyon Katsayısı
R^2	: Determinasyon Katsayısı
RBF	: Radyal Tabanlı Yapay Sinir Ağları
RMSPE	: Ortalama Yüzde Hata Kareleri Kökü
SOM	: Self-Organizing Map (Kendi Kendini Haritalama)
YSA	: Yapay sinir ağı
x	: Girdiler

w : Ağırlıklar
 φ : Aktivasyon fonksiyonu
 Σ : Toplama fonksiyonu
 Y : Çıktı




1. GİRİŞ

Her geçen gün teknoloji gelişmekte ve gelişmeye de devam etmektedir. Bu gelişmeler insanların hayatlarını kolaylaştırırken işletmeler arası rekabeti de beraberinde getirmektedir. Sektörde devamlılık ve karlılıklarını arttırmayı en önemli amaç olarak gören işletmelerin hayatta kalabilmeleri uyguladıkları rekabet stratejilerine bağlıdır. Rekabet stratejilerinin artık; kalıcı ürünler, uzun vadede değişmeyen müşteri talepleri, belirli pazar ve bilinen rakipler yerine değişen ürünler, değişen müşteri talepleri, kısa ürün yaşam çevrimleri, hızlı tedarik ve küresel pazarlara yönelik üretilmesi gerekmektedir. Bu stratejiler işletmelerin kabiliyetlerini kullanarak yapabileceği yenilikçi faaliyetlere bağlı olarak gelişecektir. İşletmeleri sürekli bu yenilikçi faaliyetlere ve üretime sürükleyen itici güç müşteri memnuniyetini sağlamaktır.

Müşteri memnuniyeti için ürün kalitesi, fiyat, güvenilirlik, gibi birçok faktör ne kadar önemliyse müşterinin talep ettiği termin sürelerine bağlı olarak olası üretim gecikmelerinin önüne geçmek de o kadar önemlidir. Müşteri taleplerini zamanında karşılamak ise ancak tedarik zinciri süreçlerini doğru planlamak ile mümkündür. Bu süreçlerden biri olan üretim için hammadde tüketimi, işgücü planlaması kadar makine duruşları da önem arz etmektedir. Çalışmaya konu olan halı üretimi dokuma prosesinde yer alan çağ değişim süreleri de bu makine duruşları kapsamında değerlendirilebilir.

Şekil 1.1’ de TradeMap verilerine göre; 2019 yılında Çin küresel halı ihracatında birinci sıradayken, Türkiye küresel ihracattan aldığı %14 pay ikinci sıradadır (Türkiye İhracatçılar Meclisi Halı Sektör Raporu, 2020).



Şekil 1.1. Küresel halı ihracat dağılımı

Makine halısı üretiminde Türkiye'nin dünya ticaretindeki rolü açıkça görülmektedir. Türkiye'de de halı üretimi büyük oranda Gaziantep ilindeki işletmeler tarafından gerçekleştirilmektedir. Türkiye'nin toplam halı imalatının yaklaşık %85'i makine halısı olup Gaziantep tüm ülkenin makine halı üretiminin %89'unu sağlamaktadır. Türkiye'de üretilen halıların %60'ı ihraç edilmekte olup ihraç edilen halıların %88'i makine halısından ve %12'lik kısmı el yapımı halılardan oluşmaktadır (Türkiye İhracatçılar Meclisi Halı Sektör Raporu, 2020). Bu veriler, Türkiye ve Gaziantep ili özelinde halı ihracatının önemini, aynı zamanda makine halısı üretiminde rekabet avantajını korumak için devam etmesi gerektiğini göstermektedir. Ayrıca, Gaziantep' te bulunan halı üretimi yapan firmalar yakın lokasyonlarda bulunmaktadır. Yurtiçi ve yurtdışı müşteri potansiyeli bulunan ve birbirleriyle rekabet halinde olan bu firmalar için doğru tedarik zinciri yönetimi burada çok önemlidir. Halı üretiminde dokuma prosesinde çağ değişim sürelerini doğru tahmin etmek buna göre planlama yapmak üretim akışının aksamaması için kritik öneme sahiptir.

Gaziantep Organize Sanayi Bölgesinde bulunan halı dokuma makinaları genel olarak Van de Wiele markasından oluşmaktadır. Bu makine ile dokunan


halının teknik ve fiziksel özelliklerine göre farklı çeşitleri bulunmakta olup Çizelge 1.1’ de gösterilmiştir.

Çizelge 1.1. Van de Wiele makine modelleri

Makine Tipi	Makine Modeli	Açıklama
Van de Wiele	CRT	Carpet & Rug Tranic
	CRX	Carpet & Rug Explorer
	SRX	Shaggy Rug Explorer
	UCL	Universal Cut & Loop
	USX	Universal Shaggy Explorer


1.1. Halının Yapısı

Makine halı dokumacılığı atkı, çözgü ve hav ipliğinden oluşur. Halı dokuma yöntemlerinden biri olan yüz yüze yöntemi ile halı oluşturulurken iki halı aynı anda dokunur. Şekil 1.2’ de görülmektedir. Oluşan iki halı arasındaki ilme yani hav yüzeyini oluşturan iplikler ortadan kesilerek aynı desene sahip iki ayrı halı elde edilir.



Şekil 1.2. Yüz yüze ile dokunmuş halının görünüşü (Van de Wiele Weave Structure Catalogue, 2003)

Gerek çözgü gerekse atkı ipliklerinin birkaç hareketten sonra belirgin bir şekilde ilk hareketlerin den başlayarak hareketlerini tekrarlamaktadır. İşte bu hareketlerin düzenli olarak tekrarlandıkları noktaya kadar olan çözgü ipliklerinin sayısı çözgü raporu atkı ipliklerinin sayısı ise atkı raporunu oluşturur. Her ikisinin birleşmesiyle de örgü raporu meydana gelir. Şekil 1.3'te makine halısı dokuma kesiti gösterilmektedir.




Şekil 1.3. Makine halısı dokuma kesiti (Van de Wiele Weave Structure Catalogue, 2003)

Yüz yüze halı yapısında temel olarak dört iplik grubu bulunur. Bunlar; zemin çözgüleri, hav çözgüsü, dolgu çözgüleri ve atkıdır (Bayramoğlu, 2018).

Zemin Çözgüsü: Halıların zeminlerini oluşturan çözgü ipliğidir.

Hav Çözgüsü: Halı yüzeyinde havları oluşturan ipliklerdir. Şekil 1.4' te gösterilmektedir. Hav iplikleri genellikle çağlık adı verilen peteklerden belirli bir sisteme göre dizilmiş bobinlerden gelir. Hav ipliklerinin tüketimi dokunan halı deseninin renklerine göre farklılıklar gösterir. Bu yüzden hav iplikleri, dokuma makinesi arkasındaki hav iplik bobinlerinin dizildiği çağlıktan verilir. Çağlık üzerinde dokunacak halının eninde bulunan hav sütunlarının renk katı kadar hav için hazırlanmış bobinler bulunur.




Şekil 1.4. Hav yüzeyi(Van de Wiele Weave Structure Catalogue 2003)

Dolgu Çözüğü: Halıda hav yüzeyini oluşturan çözgü ipliklerinin oluşturduğu ilmelerin bağlantıların sıkıştırarak daha sağlam bir yapıya sahip olmalarını sağlayan ve halıya belirli bir kalınlık sağlayan ipliklerdir.

Bağlantı Çözüğü: Halıda hav yüzeyini oluşturan hav çözgüleri atıkları bir alttan bir üstten sıkıştırarak daha sağlam bir yapıya sahip olmalarını sağlayan zemini oluşturan ipliklerdir.

Atkı İpliği: Halının zeminini oluşturan iplik grubunun ikincisidir. Çözgüler arasında açılan ağızlığa atılarak çözgü iplikleri ile belirlenen desene göre kesişmeleri sağlanır.



Şekil 1.5. Halı dokuma makinesi (Van de Wiele Weave Structure Catalogue, 2003)

Şekil 1.5’ te Van De Wiele makinesine yandan bakıldığında sağ tarafta ilme iplikleri için cağlık kısmı daha sonra zemin çözgüleri için leventler ve dokuma kısmı dokuma kısmının üst tarafındaysa jakar kısmı görülmektedir. Makinenin en solunda ise oluşan iki halının toplandığı katlama kısmı görülmektedir.

1.1.1. Cağ

Dokuma makineleri arkasında hav çözgülerinin muhafaza edildiği 2 kattan oluşan kısımdır. Cağ kapasitesini tarak numarası, makine eni ve renk sayısı belirler. Tezgâhın arka kısmında, hav ipliklerinin sarılı olduğu bobinleri taşıyan raf sistemidir. Cağ aynı ipliğin girildiği yatay bölümlere ayrılır. Hav çözgülerinin alındığı bobinlerin desene göre belirli bir düzenle yerleştirildiği kısımdır. Bu bölümler renk sırası, sıra veya kor diye adlandırılır. Aynı sıradaki renklerin tümü tezgâhın karşılık gelen tarak dışından geçerler. Bir cağ belli bir anda bir renk grubuna ayarlıdır. Bir tezgâhta yalnızca o tezgâhın cağlığında bulunan renkleri kullanan halılar dokunabilir. Dolayısıyla bir tezgâha halı yüklemesi yapılırken desenin ve cağlığın renk gruplarının uyumlu olmasına dikkat edilir. Cağda ayarlı olan renk grubunu değiştirmek mümkün olmakla birlikte yalnızca bir rengin değişmesi

yaklaşık 6 işçi saatine mal olduğundan renk değişimi zorunlu olmadıkça yapılmaz (Bayramoğlu, 2018).

Cağdaki kısımlar kanat olarak nitelendirilir. Bu kanatlar 4 parçadan oluşur ve her bir parçaya petek denir. Cağa takılan bobinler kılavuz üzerinden petek rehberlerinden geçerek cağın dışındaki ana rehberler ile makineye doğru ilerler. Her ipliğin kendi kılavuzu vardır ve kılavuz ile bobin arasında iken bobin sert sağım şeklinde yerleştirildiği için hem önüne hem de arkasına belli bir gerginlik sağlamak için ağırlık takılır. Şekil 1.6' da cağ bölümü gösterilmektedir.



Şekil 1.6. Cağ bölümü (Kohan Journal, 2018)

Cağ bölümünde dikkat edilmesi gereken hususlar vardır.

- Bobinin iplik çıkış yönü tezgâha ters olmalı
- İpliklere takılan ağırlıklar iyi ayarlanmalı
- Çok Kullanılan (çözgü havları) renkler (Halı içinde sürekli kullanılıp daha çabuk biteceği için sık sık değiştirilmesi gerekecek) mümkünse alt cağa ve görevlilerin kolayca alacağı yükseklikteki bobin sıralarına takılmalı


- Double yapacak renklerin birinin alt çağda diğerinin üst çağda ve orta kısımlar da olması gerekir (orta dan rahat gelir ve düzgün bir yüzey oluşur.).
- En çok kullanılacak iki renkten birisi üst çağda diğeri alt çağda konulmalı. Çünkü 6 renk çalışan bir tezgâhın 3 rengi alt çağda 3 rengi de üst çağda takılır. Desende çok kullanılan iki rengin ikide alta ya da üstte yer alırsa alt çağdaki ölü renkler alt haliya üst çağda ki ölü renkler üst haliya verilir. Diyelim ki ana iki renk (halıda çok çalışan renkler) alt çağ da o zaman alt halıdaki ölü hav sadece bir iplik üst çağ da ise 3 adet ölü renk (halının hav ile sırtı arasında gözükmeyen renk) olacağından üst halının ağırlığı daha fazla olacaktır. Bu nedenle renkler alt ve üst çağda dengeli takılmalıdır.
- Halının sırtında ki ölü hav çözgülerinin koyu renkleri alt ve üst haliya eşit takılmalı
- Çağdaki bobinlerin çapı küçüldükçe gerginliği azalır ve halının sırtında köpürme yapar (Bayramoğlu, 2018).

Tekstil endüstrisinde artan rekabet ile halı dokuma işletmeleri, düşük üretim verimliliği, yüksek üretim maliyeti, yüksek işçilik maliyetleri ve büyük kuyruk ipliği telefı gibi sorunlarla karşı karşıya kalmaktadır (She ve ark., 2014).

Tezgâh halı dokurken, işçiler hangi bobinin bitmek üzere olduğunu kontrol etmeli ve değiştirmelidir. Halı fabrikasında, tüm ipliklerin değiştirilmesini gerektiren çok sayıda farklı sipariş vardır. Bu da ciddi zaman ve malzeme israfına neden olur. Çağlıklar bu süreçte bir darboğaz oluşturur ve daha kısa çalışma boyutlarına izin vermenin yanı sıra işçilik, atık ve değiştirme süresini azaltmak için yeni bir çözüm gereklidir. Çağlık değişim tahminini problemi bu gibi durumlarda ortaya çıkmıştır (Guo ve ark., 2011).

1.2. Tahminleme

Tahmin gelecekteki durumun öngörülmesidir. Tahminler gerçeğe ne kadar yakın olursa, yarın için daha etkili kararlar alınabilir. Tahminleme genel anlamda işletmelerin farklı alanlarında kritik öneme sahiptir. Şekil 1.7’de uygulamaların işletme fonksiyonlarına göre farklılıkları görülmektedir.



Şekil 1.7. Tahminlemenin kullanıldığı yerler (Jain, C.L., Malehorn, J., 2012)

İşletmeler stratejilerini kısa ve uzun vadede tahminler yaparak tahminleme sonuçlarına göre belirlemektedirler. Kısa vadeli tahminlere satış alanlarını örnek gösterecek olursak, uygun satış politikasının hazırlanmasında yardımcı olur. Uzun vadeli tahminler ise uygun sermaye planlamasında yardımcı olur. Büyük stratejik kararlar için tahminler önemli bir girdi kaynağıdır. Tahminleme ile malzemede, işgücü saatlerinde, makine zamanındaki ve kapasitedeki israfları kurtarmaya yardımcı olur. Yeni bir hattın veya iş kolunun planlanması, işletmenin ürünlerinin uzun vadeli talep potansiyeli analizi göz önüne alınarak yapılmalıdır (Ahmetoğlu, 2018).

Tahminlemenin en önemli avantajı işletmenin geleceği hakkında kararlar almak için kullanabileceği değerli bilgileri sağlamasıdır fakat unutmamak gerekir ki geleceği tamamen doğru ve hatasız bir şekilde tahmin etmek mümkün değildir. Tahminlerin nitel verilere dayanmasından dolayı, verilerin yorumlanmasına bağlı olarak bir işletme farklı senaryolar üretebilir. Bu sebeple, işletmeler hiçbir tahmin modeline yüzde yüz güvenmemelidir. Bununla birlikte, bir işletme, geleceğe dair mümkün olan en iyi bilgileri vermek için, tahmin modellerini diğer analiz araçlarıyla etkin bir şekilde kullanılabilir. Kötü bir tahmine göre karar vermek, işletme için maddi zarara yol açabilir; bu nedenle, bir işletme kararlarını yalnızca bir tahmini temel alarak vermemelidir (Bass, 2018).

Her sektörde ciddi derecede katkı sağlayan tahminleme, üretim yapan işletmelerde ise pek çok farklı noktada planlama için vazgeçilmezdir. Hammadde tedariki, lojistik süreçleri, üretim ve satın alma planlaması, yatırım planlaması gibi üretimi doğrudan etkileyecek proseslerde sorun yaşanmaması için olmazsa olmazdır. Geleceği öngörmek zor olsa da doğru ya da yaklaşık veriler ile planlama yapılması işletmenin stratejik hedeflerine bağlı hareket etmesini sağlar.

1.2.1. Tahmin Yöntemleri

Tahmin yöntemleri kalitatif ve kantitatif olarak iki ana kategoride sınıflandırılmaktadır.

Kalitatif tahminleme yöntemleri, mevcut durumlara ve gelecekle ilgili planlara ilişkin bilgisi olması muhtemel kişilerin fikir ve yargılarının toplanmasını gerektirmektedir. Bu yöntemler karar verme sürecinde kişisel önyargıların bulunmasından dolayı genellikle daha düşük performansa sahip tahminlerle sonuçlanmaktadır (Monks, J.G., 1987).


Kantitatif tahminleme yöntemleri, zaman serileri ve nedensel yöntemler (regresyon analizi) olmak üzere iki gruba ayrılmaktadır (Bhattacharya, S., 1997).

Zaman serisi yöntemleri, regresyon modellerinde olduğu gibi bağımsız değişkenlerle ilgilenmez. Zaman serisi yöntemleri, yalnızca tahmin edilen

değişkenle ilgili geçmiş verileri kullanır. Bu yöntemlerde temel varsayım, bağımlı değişkenin tarihsel örüntüsünün gelecekte de devam edeceğidir (Krajewski ve ark., 2013). Bu özelliğinden dolayı zaman serisi yöntemleri, değişmeyen şartlarda daha etkin olmaktadır.

Nedensel tahminleme yöntemleri, diğer bir adıyla regresyon analizi, geçmiş verilerin mevcut olduğu, bağımlı ve bağımsız değişkenler arasındaki ilişkinin tanımlanabildiği durumlarda, tahmin için kullanılan yöntemlerdir. Doğrusal regresyon, en bilinen ve yaygın olarak kullanılan tahmin yöntemlerinden biridir. Doğrusal regresyonda iki tür değişken vardır. İlki, tahmin edilecek değişken olan bağımlı değişkendir. İkincisi, bağımlı değişkeni etkilediği varsayılan bağımsız değişkendir (Krajewski ve ark., 2013).

Şekil 1.8’ de tahminlemede kullanılan yöntemlerin sınıflandırılması görülmektedir.



Şekil 1.8. Tahminlemede kullanılan yöntemlerin sınıflandırılması (Bal, 2015)

1.3. Regresyon Analizi

Regresyon analizi, değişkenler arasındaki ilişkiyi analiz etmek için kullanılan istatistiksel tekniklerden biridir. Genel olarak, araştırmayı yapan kişi belirli bir değişkenin başka bir değişken üstündeki etkisini ve aralarındaki ilişkiyi araştırır. Nüfusun satışa etkisi, doların alım gücüne göre değişiklik etkisi gibi iki temel örnek olarak verilebilir. Bu konuları araştırmak için araştırma yapacak kişi aradaki ilişkinin odağında olan kısıtları birleştirerek ve kısıtları etkileyen nedensel değişkenlerin kantitatif etkisini belirlemek adına regresyon modelini çalıştırır. Bunun dışında araştırmacı, belirlenen ilişkilerin “sayısal anlamını” yorumlar. Yapılan bu yorumlama sonundaki değerlendirmede, gerçekleşen ilişki seviyesinin tahminlenen ilişki seviyesine ne kadar yakın olduğunun güvenilirlik derecesidir (Orhunbilge, 1996).

Regresyon analizi, bağımsız değişken sayısına göre:

1. Basit regresyon analizi (Tek bağımsız değişken)
2. Çoklu regresyon analizi (Birden çok bağımsız değişken) olmak üzere iki grupta,

Fonksiyon tipine göre:

1. Doğrusal regresyon analizi
2. Doğrusal olmayan regresyon analizi (eğrisel) olmak üzere iki grupta,

Verilerin kaynağına göre:

1. Ana kütle verileriyle regresyon analizi,
2. Örnek verileriyle regresyon analizi,
3. Zaman serilerinde regresyon analizi olmak üzere 3 gruba ayrılır (Orhunbilge, 1996).

1.3.1. Basit Doğrusal Regresyon Analizi

Basit doğrusal regresyon analizi, bir bağımsız değişken ile bir bağımlı değişken arasındaki doğrusal ilişkiyi açıklamak için kullanılan istatistiksel bir

tekniktir. Bağımlı değişken, varyasyonunun açıklanması gereken bir değişkendir. Bağımsız bir değişken, bağımlı değişkenin varyasyonunu açıklığa kavuşturan bir değişkendir. Basit regresyon analizi denklem (1.1) olarak gösterilebilir (Krajewski ve ark., 2013):

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (1.1)$$

y = bağımlı değişken

x = bağımsız değişken

β_0 = popülasyonun y kesişimi

β_1 = regresyon çizgisinin eğimi

ε = hata terimi

β_1 katsayısı, x değişkenindeki bir birim değişime göre y değişkenindeki ortalama değişimi gösterir. Bu katsayı, bağımlı ve bağımsız değişkenler arasındaki ilişkiye göre sıfır, pozitif veya negatif değerini alabilir. β_0 katsayısı, x 'in sıfır olması durumunda y 'nin ortalama değerini gösterir.

Bir veri kümesi kullanarak bir regresyon modeli oluştururken, bu veri noktaları için çok fazla olası regresyon çizgisi olabilir. Bu durumda, en iyi hattı seçmek için bir kriter belirlenmelidir. Bu kriter "en küçük kareler kriteri" dir. En küçük kareler kriteri, "karesel tahmin hatalarının toplamını en aza indiren bir regresyon çizgisini belirleme kriteri" olarak tanımlanır. En iyi regresyon çizgisinde tahmin hatalarının toplamı sıfırdır. Başka bir deyişle, basit doğrusal regresyonun amacı β_0 ve β_1 katsayılarının değerini elde etmektir, böylece gerçek verilerin karesel sapmalarının toplamı en aza indirilir. Bu nedenle basit doğrusal regresyon grafiği kullanılabilir (Krajewski ve ark., 2013).

1.3.2. Çoklu Doğrusal Regresyon Analizi

Çoklu doğrusal regresyon analizi, bir bağımlı değişken ile birden fazla bağımsız değişken arasındaki doğrusal ilişkiyi açıklamak için kullanılan istatistiksel bir tekniktir. Çoklu doğrusal regresyon modeli denklem (1.2) olarak gösterilebilir (Krajewski ve ark., 2013):

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_kx_k + \varepsilon \quad (1.2)$$

β_0 = popülasyon sabiti

β_1 = her değişken ($x=1, 2, 3, \dots, k$) için popülasyonun regresyon katsayısı

k =bağımsız değişkenlerin katsayısı

ε = model hatası

Basit doğrusal regresyon ve çoklu doğrusal regresyon arasındaki temel fark, basit doğrusal regresyonun iki boyutlu uzayda düz bir çizgi oluşturması, ancak çoklu doğrusal regresyonun çok boyutlu uzay boyunca bir hiper düzlem oluşturmasıdır.

1.3.3. Doğrusal Olmayan Regresyon Analizi

Çoğu durumda, iki değişken arasında doğrusal bir ilişki vardır. Öte yandan, bazı durumlarda iki değişken arasında eğrisel ilişki vardır. Örneğin bazı bölgelerde nüfus artışına göre elektrik talebi üstel bir oranda artmıştır. Değişkenler arasında eğrisel ilişki varsa, "eğriler" üretecek terimler MLP modeline dâhil edilmelidir. Bu eğrileri oluşturmak için dahil edilen terimlerin üsleri 1'den büyük olmalıdır. Bir modelin böyle terimleri varsa, buna polinom modeli denilebilir. Denklem (1.3)' te; tek bağımsız değişkenli polinom modeli için en çok kullanılan denklem gösterilmiştir (Krajewski ve ark., 2013):

$$y = \beta_0 + \beta_1x + \beta_2x^2 + \dots + \beta_px^p + \varepsilon \quad (1.3)$$

β_0 = popülasyon sabiti

β_1 = her değişken ($x=1, 2, 3, \dots, k$) için popülasyonun regresyon katsayısı

p = polinom derecesi

ε = model hatası

Bağımsız değişkenin en büyük üssü, modelin derecesini belirler.

1.4. Yapay Sinir Ağları

Yapay sinir ağları (YSA), yapay zekâ üzerine yapılan çalışmalarda en çok kullanılan yöntem olarak karşımıza çıkmaktadır. Son yıllarda yapay sinir ağlarına olan ilgide artış olduğu da yapılan çalışmalardan görülmektedir. Mühendislik, tıp, felsefe, psikoloji, tarım gibi alanlarda çalışanlar kendi alanlarında YSA uygulamalarını geliştirmeye başlamışlardır. Teorik ve uygulama alanlarındaki başarılarla bu ilgi daha da kuvvetlenmiştir. İnsan zekâsına özgü gibi görünen bazı alanların sayısal olarak ifade edilebileceği ve böylece makinelerin insan zekâsına şaşırtıcı derecede benzer yollarla öğrenme ve hatırlama işlerini yapabileceği görülmüştür (Haykin, 1999).

1.4.1. Yapay Sinir Ağlarının Tanımı

YSA, biyolojik sinir ağları ile ortak belirli özelliklere sahip bir bilgi işleme sistemidir.

Literatürde geçen YSA tanımlarından bazıları şunlardır:

“Yapay sinir ağı, deneyimsel bilgiyi depolamak ve kullanıma hazır hale getirmek için doğal bir eğilime sahip, basit işlem birimlerinden oluşan, büyük ölçüde paralel dağıtılmış bir işlemcidir” (Haykin ve Haykin, 2009).

“YSA, biyolojik sinir ağlarıyla ortak bazı özelliklere sahip bir bilgi işleme sistemidir. YSA, insan bilişinin veya sinir biyolojisinin matematiksel modellerinin genellemeleri olarak geliştirilmiştir” (Fausett ve Fausett, 1994).

“Yapay sinir ağları, insan beyninin önemli özelliklerinden biri olan öğrenme yolu ile yeni bilgiler üretebilme, keşfedebilme gibi yetenekleri hiçbir yardım olmaksızın kendiliğinden ortaya koymak amacıyla tasarlanan bilgisayar sistemleridir” (Öztemel, 2003).

Özetle YSA, insan beyninin yeni bilgi öğrenme ve üretme yeteneğinden esinlenen ve özellikle doğrusal olmayan problemlerin çözümlerinde farklı alanlarda ve amaçlarla kullanılan matematiksel bir sistemdir.

1.4.2. Yapay Sinir Ağlarının Tarihçesi

Yapay sinir ağlarının tarihçesi insanların nörobiyoloji konusuna ilgi duyması ve elde edilen bilgileri bilgisayar bilimine uygulamaları ile başlamaktadır.

1943 yılında Warren McCulloch ve Walter Pitts tarafından ilk yapay sinir ağ modeli gerçekleştirilmiştir. Bir nörobiyolojist olan Warren McCulloch ve bir istatistikçi olan Walter Pitts, “Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap” başlıklı bir makale ile ilk dijital bilgisayarlara ışık tutmuştur. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı modellemişlerdir. Yapay sinir hücreleri ile her türlü mantıksal ifadeyi formüle etmenin mümkün olduğunu göstermişlerdir. Hücrelerin birbiri ile paralel çalışması gerektiği fikrini ortaya atarak öğrenme kurallarını belirlemeye başlamışlardır (Elmas,2003).

1949 yılında, neredeyse tüm sinirlerin temelini oluşturan klasik Hebbian Kuralı öğrenme prosedürleri Donald Hebb tarafından formüle edilmiştir. Hebbian Kuralı, iki nöron aynı anda aktif olduğunda, aralarındaki bağlantıların güçlendiğini belirtir (Kriesel, 2005).

1951 yılında ilk neuro-bilgisayar üretilmiştir.

1954 yılında rassal ağlar ile adaptif tepki üretme kavramları Farley and Clark tarafından ortaya atılmıştır ve bu kavramlar 1958 yılında Frank Rossentblatt ve 1961 yılında Caianiello tarafından geliştirilmiştir.

1957 yılında Frank Rossentblatt tarafından geliştirilen algılayıcı model (perceptron) sonrası yapay sinir ağı alanındaki gelişmeler hızlanmıştır. Yapay sinir ağlarında devrim niteliğinde olacak olan çok katmanlı algılayıcıların temelini oluşturan “Perceptron”, beyin fonksiyonlarını modellemek vasıtasıyla meydana gelen, tek katmanlı ve tek çıkışlı bir ağıdır (Elmas, 2003).

1959’ da Stanford üniversitesinde Bernard Widrow ve Marcian E. Hoff tarafından geliştirilen hızlı ve kesin bir uyarlamalı öğrenme sistemi olan ADALINE (ADAPtive LInear NEuron) tanıtıldı. (Widrow, Hoff, 1960).

1960’lı yıllarda yapay sinir ağları üzerine Grosberg, Kohonen, Rosenblatt, Widrow, Nilssons, Fukushima vb. gibi bilim adamlarının çalışmaları olmuştur. Özellikle Nilssons tarafından yazılan ilke “Öğrenen Makineler” adlı kitap yapılan çalışmaların teorik çerçevesini oluşturmaya ve çalışmaları bir araya getirmeye neden olmuştur.

1969 yılında; Marvin Misky ve Seymour Papert tarafından bir algılayıcıya ilişkin belirli bir matematiksel analiz yapılmıştır. Bu analiz, XOR problemleri gibi bazı önemli problemlerin bir perceptron modeli kullanılarak çözilemeyeceğini gösterdi. Bu arayış, bilimsel çevreleri yapay bir sinir yapılamayacağına inandırmış ve yapay sinir ağları alanındaki çalışmaların bir anda durmasına neden olmuştur (Kriesel, 2005).

Minsky ve Papert tarafından tek katmanlı ağların birçok konuda yetersiz kaldığının gösterilmesi yapay sinir ağları üzerindeki çalışmaları bir süre durdurmuştur. Hatta bu olumsuz gelişmeler birçok araştırmacının hayal kırıklığına uğramasına sebep olmuştur. 1970’li yılların başından 1980’li yıllara kadar bu durgunluk devam etmiştir. Bu tarihler arasında kendi kişisel çabalarıyla bazı bilim adamları çalışmalarını sürdürmeye devam etseler de önemli bir ilerleme sağlanamamıştır (Şen, 2004)

1972’de Kohonen, Korelasyon Matris Belleği’ni geliştirmiştir. Özellikle örüntü tanıma ve sınıflandırma gibi verideki benzer davranışların analizi ve veri

yapısının ortaya çıkarılması gibi problemlerde bu model kullanılmaktadır (Kohonen, 1984).

1980'lerin başında Fukushima, görsel şekil ve yapıları tanımla amacıyla geliştirdiği NEOCOGNITRON modelini tanıtmıştır. Önceleri bu model danışmansız öğrenme için geliştirildiyse de daha sonra danışmanlı öğrenme yapabilecek düzenlemelere yer verilmiştir. Fukushima'nın çalışmaları, bu alandaki mühendislik uygulamalarının sayısını arttırmıştır. Daha sonraki dönemde yapay sinir ağlarının mühendislik alanında kullanımında örüntü tanıma hakkında yayınladığı çalışmalarla örnekler vermiştir (Fukushima, 1986).

1982 yılında John Hopfield, Ulusal Bilimler Akademisi'ne moleküller biyolojiden beyin kuramcılığına geçiş yapan bir model sunmuştur. Kendi adıyla anılan bir ağ yapısı mevcuttur ve birçok alana uygulanmıştır. Hopfield'in yaklaşımı beyne benzeyen basit bir model değil, kullanışlı bir alet oluşturmaktı. Açık ve matematiksel analizleri kullanarak, böyle bir aletin nasıl çalışacağını ve ne yapabileceğini göstermiştir (Elmas, 2003).

1984'de Kohonen sinirlerin düzenli sıralanışına eşleme özelliği için danışmansız öğrenme yönteminin kullanıldığı öğrenme ağları geliştirmiştir (Kohonen, 1984).

1986 yılında Rumelhart, Hinton, Williams ve McClelland tarafından çok katmanlı algılayıcı tipi ağlar için "geri yayılma" olarak adlandırılan öğrenme algoritması geliştirilmiştir. Geri yayılma algoritması ile çok katmanlı ağların tek katmanlı ağların çözemeyeceği problemleri çözebildiğini ortaya koyulmuş olup XOR Problemini, bir geri yayılma ağı ile çözerek, yapay sinir ağları araştırmalarının önündeki engeller ortadan kaldırılmıştır. Ayrıca bu algoritma güçlü olmakla birlikte oldukça karmaşık matematik esaslara dayanmaktadır. Bu algoritmanın etkin bir öğrenmeyi mümkün kılma yeteneği dikkatleri üzerine çekmiştir. Günümüzde dahi en çok kullanılan öğretim sistemlerinden biri olan bu algoritmanın ortaya çıkarılması yapay sinir ağları alanında çığır açmıştır (Mehrotra ve ark., 1997).

1988’de Broomhead ve Lowe tarafından, Radyal Tabanlı Fonksiyonlar (Radial Basis Functions – RBF) sinir ağlarının bir modeli geliştirilmiştir. Broomhead ve Lowe makalelerinde bu sinir ağının çok katmanlı algılayıcı sinir ağlarına alternatif olabileceğini belirtmişlerdir (Broomhead ve Lowe, 1988).

1990’da Daniel Specht tarafından Olasılıksal Sinir Ağları (Probabilistic Neural Networks- PNN) geliştirilmiştir. Olasılıksal sinir ağları, radyal tabanlı fonksiyonlar modelinden daha gelişmiş bir modeldir. Çalışmalarını sürdüren Specht, 1991 yılında, Genelleştirilmiş Regresyon Ağları’nı (Generalized Regression Neural Networks- GRNN) geliştirmiştir (Specht, 1991). PNN ve GRNN, Gauss olasılık yoğunluk fonksiyonu gibi bir fonksiyon yardımıyla normalleştirilmiş birer radyal tabanlı ağ olarak düşünülebilirler. Her iki ağ modeli de veri ile düzgün bir fonksiyona yakınsayabilirler.

1995 yılında Grossberg, Carpenter ve Reynolds yankı algoritmaları üzerine çalışmışlardır (Grossberg ve ark., 1995). Bu araştırmalar sonucunda bugün yapı tanımlama alanında sıkça kullanılan Uyarlanabilir Yankı Teorisi’ni (Adaptive Resonance Theory – ART) geliştirmişlerdir (Çelik, 2008).

1997’de Hochreiter, Sepp, Schmidhuber ve Juergen yapay sinir ağları için Uzun ve Kısa Dönem Hafıza teorisini (Long – Short Term Memory) geliştirmişlerdir (Hochreiter ve Schmidhuber, 1997). Bu çalışmayla yapay sinir sistemlerinin biyolojik sinir sistemi ve insan beynini taklit edebilme yeteneği bir sonraki seviyeye taşınmıştır. Özellikle konuşma tanımlama (speech recognition) problemlerinde bu çalışma etkin bir şekilde kullanılmaktadır (Çelik, 2008).

2003’te Ortiz, Gers, Eck ve Schmidhuber Uzun ve Kısa Dönem Hafıza yöntemiyle geliştirilmiş bir Kalman filtreleme yöntemi kullanmışlar ve bu yeni yöntemle geleneksel ağ yapıları ile çözilemeyen bazı problemleri çözebildiklerini göstermişlerdir (Perez – Ortiz ve ark., 2003). Ayrıca bu yöntemle ağın eğitimi için gereken döngü sayısının da anlamlı derecede azaldığını belirtmişlerdir (Çelik, 2008).

1.4.3. Yapay Sinir Ağlarının Kullanım Alanları

Yapay sinir ağları gerçek hayatta karşılaşılan problemlerde oldukça geniş bir uygulama alanı kazanmışlardır ve birçok alanda başarılı şekilde kullanılmaktadırlar. Uygulama alanlarında bir sınır yoktur ancak sınıflandırma, öngörü ve modelleme gibi bazı alanlarda daha fazla kullanılmaktadırlar (Yurtoğlu, 2005). YSA uygulamaları; doğrusal olmayan, çok boyutlu, karmaşık, kesin ve tam olmayan, hata olasılığı çok veriler ile oluşturulan problemlerin çözümünde kullanılmakta ve sonuçlar başarılı bulunmaktadır (Öztemel, 2003).

YSA, çok değişken ve karmaşık etkileşim içeren üretim süreçleri için mükemmel sistemlerdir. Genel olarak YSA kullanılabilecek uygulamalar aşağıdaki gibi özetlenebilir (Gürsoy, 2012):

a) Yapay sinir ağlarının kullanıldığı teorik uygulamalar:

- Doğrusal olmayan sistem modelleme
- Akıllı kontrol
- Sinyal filtreleme ve doğrusal olmayan sinyal işleme
- Optimizasyon
- Probabilistik fonksiyon kestirimleri
- Sınıflandırma
- Örüntü tanıma, ilişkilendirme ve eşleştirme

b) Yapay sinir ağlarının kullanıldığı pratik uygulamalar:

- Kimyasal süreçlerin modellenmesi
- Akıllı araçlar ve robotlar için en iyi rota belirleme
- Robotlarda görme sistemlerinin ve hareket mekanizmalarının kontrol edilmesi
- Makina, sistem ve süreçler için arıza tespiti

- İletişim kanallarındaki ekoların filtrelmesi, anahtarlama ve yoğunluğun kontrolü
- Hedef tanıma ve takip sistemleri
- Radar ve sonar sinyallerinin sınıflandırılması
- Radar ve görüntü sinyalleri işleme
- Güvenlik sistemlerinde konuşma ve parmak izi tanıma
- Mekanik parçaların ömürlerinin ve kırılmalarının tahmin edilmesi
- Endüstriyel ürünlerin görsel kalite kontrolü ve imalatı meydana gelen hataların tespiti
- Kredi kartı hilelerinin tespiti
- Döviz kuru tahminleri, risk analizleri

Yapay Sinir Ağlarının uygulama alanları kullanım amaçlarına göre de şöyle gösterilebilir (Elmas, 2003):

Sınıflandırma: Müşteri/Pazar profilleri, imza incelemeleri, tıbbi tanı, borçlanma/risk değerlendirme, ses tanıma, şekil tanıma, spektrum tanımlaması, mal değeri, hücre tiplerinin sınıflandırılması, virüsler, modeller, örnekler

Öngörü: Gelecekteki satışlar, üretim ihtiyacı, pazar performansı, ekonomik deliller, enerji ihtiyacı, tıbbi sonuçlar, kimyasal reaksiyon ürünleri, hava tahminleri, at yarışları, çevresel risk, radyoaktif sızıntı tahminleri

Modelleme: İşlem kontrolü, sistem kontrolü, kimyasal yapılar, dinamik sistemler, işaret karşılaştırma, kaynak kontrolü, robot kontrolü vs.

1.4.4. Yapay Sinir Ağlarının Genel Özellikleri

Uygulanan ağ modeline göre yapay sinir ağlarının tipik özellikleri değişmektedir. Fakat tüm modeller için genel özellikler şunlardır (Jain, Mao ve Mohiuddin, 1996):

- Yapay sinir ağları makine öğrenmesi gerçekleştirirler.
- Yapay sinir ağlarının çalışma biçimi bilinen programlama tekniklerinden farklıdır.
- Bilgiyi saklarlar.
- Örnekleri kullanarak öğrenirler.
- Güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir.
- Görülmemiş örnekler hakkında bilgi üretirler. Bunu genelleme özelliği sebebiyle yaparlar.
- Algılamaya yönelik olaylarda kullanılabilirler.
- Şekil ilişkilendirme ve sınıflandırma yapabilirler.
- Örüntü tamamlama gerçekleştirebilirler.
- Kendi kendine organize etme ve öğrenebilme kabiliyetleri vardır.
- Eksik bilgi ile çalışabilmektedirler.
- Hataya ve gürültüye karşı duyarlılığa ve toleransa sahiptirler.
- Dereceli bozulma gösterirler.
- Veri dağıtılmış birleşik hafıza yapısı kullanılır ve bilgi farklı formlara dönüştürülerek işlenebilir.
- Sadece nümerik veriler ile çalışabilmektedirler.

1.4.5. Yapay Sinir Ağlarının Avantaj ve Dezavantajları

Bir yapay sinir ağının gücünü iki özellikten aldığı söylenebilir: Birincisi, yapısıdır. Bir YSA paralel bir yapı gösterir ve bu özellikler ona problem çözmede hız kazandırır. İkinci özelliği ise öğrenme ve genelleme yeteneğidir. Bunlara karşılık dezavantajları ise sistemin çalışmasının analiz edilememesi ve öğrenme işleminde başarılı olunamama riski olmasıdır (Sağıroğlu ve ark., 2003).

1.4.5.1. Yapay Sinir Ağlarının Avantajları

Yapay sinir ağları kullanılarak yapılan analizlerde, elde edilebilecek birçok avantajdan bazıları aşağıda verilmiştir:

- Şekil tanıma, ilişkilendirme, sınıflandırma ve genelleme için güçlü bir yöntemdir.
- Bir sinir ağının, çevresinde bir değişiklik meydana geldiğinde ağırlıklarını nöronlar arasında uyarlamak için dahili bir yeteneği vardır. Özellikle bir sinir ağı, çevredeki ortamdaki bazı değişikliklerle başa çıkmak için kolayca yeniden eğitilebilir. Ayrıca, bir sinir ağı durağan olmayan bir ortamda çalışırken, nöronlar arasındaki ağırlıklarını gerçek zamanlı olarak değiştirecek şekilde tasarlanabilir.
- Bir sinir ağı, paralel olarak bağlanan ve dağıtılan birkaç hücreden oluşur. Ağa giren bilgiler tüm bağlantılara dağıtılır. Ağ eğitiminde bazı hücrelerin etkisizliği, doğru bilgi üretmek için ağı önemli ölçüde etkilemez. Sonuç olarak, yapay sinir ağlarının geleneksel yöntemlere göre daha fazla hata toleransına sahip olduğu söylenebilir.
- Yapay sinir ağları, programlama yerine öğrenme yoluyla kendini geliştirir.
- Geleneksel modeller genellikle doğrusal problemler için kullanılırken, yapay sinir ağları hem doğrusal hem de doğrusal olmayan problemler için kullanılabilir.
- Matematiksel modele ihtiyaç duymazlar.
- Yapay sinir ağları, problemi çözerken geleneksel hesaplama yöntemlerine göre zamanı daha verimli kullanırlar.
- Yapay sinir ağların performansı geleneksel istatistiksel yöntemler kadar iyidir. Sinir ağları daha az zamanda veri yapısını açık şekilde yansıtan modeller oluşturur.

- YSA'lar doğrusal olmayan verilerle ve matematiksel olarak modellenmesi mümkün olmayan veya zor olan problem için rahat uygulanabilir.

1.4.5.2. Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarına dair oluşabilecek dezavantajlar şunlardır: (Elmas, 2003)

- Sistem içerisinde ne olduğu tam olarak anlaşılamamaktadır. Bu gibi durumlarda ağların çıktılarını yorumlamak oldukça zordur.
- Problemin çözümü noktasında etkili bir yöntem bulunmayabilir ya da hata yapabilirler. Nedeniyse, ağın eğitileceği bir fonksiyonunun olmamasıdır.
- Ağı eğitmek için uzun bir zaman gerekebilmektedir.
- Farklı sistemlere uyum sağlamak zordur.
- Ağın kalitesi ve kapasitesi, çalışma esnasındaki hızı ile doğru orantılıdır.

1.4.6. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağlarının daha iyi anlaşılması için biyolojik sinir ağ yapısının ve çalışma ilkelerinin bilinmesi gerekmektedir.

1.4.6.1. Biyolojik sinir ağları


Biyolojik sinir ağları, yüksek ve karmaşık olayları işleme yeteneğine sahiptir. İnsan korteksinde yaklaşık 10 milyar nöron ve aralarında yaklaşık 60 trilyon sinaps olduğu tahmin edilmektedir. Bir YSA, bilgisayarlar için bu yeteneği sağlamayı amaçlamaktadır. Bu nedenle YSA konusuna geçmeden önce biyolojik sinir hücrelerini tanımak daha faydalıdır (Haykin ve Haykin, 2009).

Biyolojik sinir sistemi, Şekil 1.9'daki blok diyagramda gösterildiği gibi üç aşamalı bir sistem olarak görülebilir (Haykin, 1999). Sistemin merkezinde, sürekli olarak bilgi alan, onu algılayan ve takdir kararları veren sinir ağı tarafından temsil edilen beyindir. Şekil 1.9' da iki ok takımı bulunmaktadır. Soldan sağa işaret edenler, bilgi taşıyan sinyallerin sistem üzerinden ileri iletimini gösterir. Sağdan sola doğru işaret eden oklar, sistemdeki geri bildirimin varlığını belirtir. Reseptörler, insan vücudundan veya dış çevreden gelen uyarıları, bilgiyi sinir ağına (beyin) ileten elektriksel uyarılara dönüştürür. Efektörler, sinir ağı tarafından üretilen elektriksel dürtüleri, sistem çıktıları olarak ayırt edilebilir tepkilere dönüştürür.



Şekil 1.9. Sinir sisteminin blok diyagram gösterimi (Haykin, 1999)

Bir sinir ağının temel işlem ögesi bir nörondur. İnsan bilincinin bu yapı taşı birkaç genel yeteneği kapsar. Temel olarak, bir biyolojik nöron diğer kaynaklardan girdi alır, bunları bir şekilde birleştirir, sonuç üzerinde genellikle doğrusal olmayan bir işlem gerçekleştirir ve ardından nihai sonucu çıkarır (Gurney, 2004). Bu ilişki Şekil 1.10' da gösterilmektedir:



Şekil 1.10. Biyolojik sinir hücresi ve bileşenleri (Bilen, 2011)

Tüm doğal nöronlar aynı dört temel bileşene sahiptir. Bu bileşenler dendritler, soma, akson ve sinapslar olarak bilinir. Sinapslar, nöronlar arasındaki etkileşimleri sağlamaktan sorumlu olan temel yapısal ve işlevsel birimlerden biridir. Dendrit, soma adı verilen hücre çekirdeğinden uzanan yapılardır ve bu yapılar ağaç dallarına benzer. Dendritin görevi elektrik sinyallerini alıp çekirdeğe iletmektir. Soma, hücrenin çekirdeğidir ve dendritlerden alınan tüm sinyalleri biriktirir. Birikmiş sinyaller belirli bir değeri (eşik değeri) aştığında, soma diğer nöronlara bir elektrik darbesi aktive eder. Diğer nöronlara elektrik darbesi aksonlar tarafından gönderilir (Kriesel, 2005).

Biyolojik nöronlar, günümüzün yapay sinir ağlarında yerleşik olan mevcut yapay nöronlardan önemli ölçüde daha karmaşıktır. Sinir ağları bir beyni yeniden oluşturmaya çalışmaz. Araştırmacılar, bu nöronların ve beynin yeteneklerinin doğasını anlamaya çalışır ve bunu henüz geleneksel hesaplama yöntemleriyle çözülmemiş mühendislik problemlerini çözmek için kullanır.

1.4.6.2. Yapay Sinir Ağları

Sinir ağları, biyolojik sinir ağları gibi sinir hücrelerine sahiptir. Yapay sinir ağları, biyolojik sinir ağlarının modellenmesidir. Çizelge 1.2' de yapay sinir ağları

ve biyolojik sinir sistemleri yapısal bazı benzerlikleri ve Çizelge 1.3'te istatistiksel ilkeler ile yapay sinir ağları arasındaki terminolojik ilişkiler gösterilmiştir (Sağıroğlu ve ark., 2003).

Çizelge 1.2. Biyolojik sinir sistemi ile YSA'nın yapısal benzerlikleri


Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Nöron (Biyolojik Sinir Hücresi)	İşlemci Elemanı (Yapay Sinir Hücresi)
Dendrit	Toplama Fonksiyonu
Soma (Hücre Çekirdeği)	Aktivasyon Fonksiyonu
Aksonlar	Eleman Çıkışı
Sinapslar	Ağırlıklar

Çizelge 1.3. İstatistiksel yöntemlerle yapay sinir ağlarının benzerlikleri

İstatistiksel	Yapay Sinir Ağları
Model	Ağ
Tahmin	Öğrenme
Regresyon	Danışmanlı Öğrenme
İnterpolasyon	Genelleştirme
Gözlem	Öğrenme Algoritması
Parametre	Ağ Parametreleri (Ağırlıklar, Katsayılar)
Bağımsız Değişken	Girdi Verileri
Bağımlı Değişken	Çıktı Verileri
Sınır Regresyonu	Ağırlık Budama İşlemi


Literatürde birçok YSA mimarisi vardır, ancak genel bir YSA mimarisi Şekil 1.11'deki gibi gösterilebilir. Giriş katmanında en az bir giriş ögesi vardır. Bu katmanda girdi elemanları herhangi bir işlem olmaksızın aynı girdi değerlerini üretir. En az bir çıktı elemanı vardır ve çıktı elemanlarında girdi elemanlarına rağmen çıktıyı üreten bir süreç vardır. İşlem katmanları genellikle kara kutu olarak

adlandırılır çünkü her bir işleme ögesi davranışını anlamak çok zor bir görevdir. Bu katmanlar ve bu katmanlarda kullanılan işlevler YSA tipine göre değişebilir (Tosun 2007).



Şekil 1.11. YSA mimarisinin blok diyagram gösterimi

Yapay sinir ağları, birbirine bağlı birkaç nörondan oluşur ve bu nöronlar (hücre) bilgi alır ve çeşitli işlevlere sahip bir çıktı üretir. Girdiler (x), ağırlıklar (w), toplama fonksiyonu (Σ), aktivasyon fonksiyonu (φ) ve çıktı (y) olmak üzere beş temel bileşenden oluşan bir yapay sinir hücresi Şekil 1.12’de gösterilmektedir.



Şekil 1.12. Yapay sinir hücresinin yapısı (Tarassenko, 1998)

Bir yapay sinir ağı hücresinin tüm bu temel bileşenleri şu şekilde açıklanabilir:

1) Girdiler

Girdiler, yapay sinir hücreleri tarafından ortamdan, diğer hücrelerden veya kendisinden alınan ve bu girdiler için çıktı üretilen bilgilerdir.

2) Ağırlıklar

Ağırlıklar (w), verilerin yapay bir sinir hücresi üzerindeki etkisini gösterir. Ağırlıkların büyük veya küçük olması, önemli veya önemsiz oldukları anlamına gelmez. Bir ağırlığın sıfır değeri, o ağ için en önemli olay olabilir. Artı (+) veya eksi (-) ağırlık, etkinin pozitif veya negatif olduğunu gösterir. Ağırlıklar değiştirilebilir veya sabit değer de olabilir.

3) Toplama Fonksiyonu

Bir hücreye gelen net girdinin hesaplanmasını sağlayan fonksiyondur. Bu amaçla farklı fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamın bulmasıdır. Bu fonksiyonda, her gelen girdi değeri kendi ağırlığıyla çarpılır. Böylelikle ağa net girdi bulunur. Ağırlıklı toplam fonksiyonunun formülü Denklem 1.4' te gösterilmiştir (Haykin ve Haykin, 2009):

$$Net = \sum_i X_i W_{kj} \quad (1.4.)$$

Bu formülde, X_i giriş sinyallerini gösterir ve W_{kj} k nöronunun ilgili ağırlıklarıdır. Bununla birlikte, bu formülü bir YSA' da kullanmak her zaman gerekli değildir. Literatürde toplama fonksiyonu olarak farklı formüller kullanılmıştır. Çizelge 1.4' te beş farklı toplama fonksiyonu ve açıklamaları verilmektedir. Çizelge 1.4' te görülebilir, her bir fonksiyonun hesaplama yöntemleri farklıdır. Bu nedenle, seçilen toplama fonksiyonu YSA modelinin performansını etkileyebilir. Toplama fonksiyonunu seçmek için tanımlanmış bir kural yoktur, bu nedenle en uygun fonksiyon deneme yanılma yoluyla bulunabilir (Öztemel, 2003).

Çizelge 1.4. Toplama fonksiyonu örnekleri

Net	Açıklama
Çarpım $\prod_i X_i W_{kj}$	Ağırlık değerleri girdilerle çarpılır ve çarpım sonucu elde edilen değerler birbiriyle çarpılarak net girdiyi hesaplanır.
Maksimum $Net = Mak (X_i W_{kj})$ $i = 1, 2, 3, \dots, N$	Girdiler ağırlık değerleriyle çarpıldıktan sonra, maksimum değer ağın net girdisi olarak kabul edilir.
Minimum $Net = Min (X_i W_{kj})$ $i = 1, 2, 3, \dots, N$	Girdiler ağırlık değerleriyle çarpıldıktan sonra minimum değer, ağın net girdisi olarak kabul edilir.
Çoğunluk (Signum) $Net = \sum_i sgn (X_i W_{kj})$	İlk olarak, her girdi kendi ağırlığıyla çarpılır ve pozitif ve negatif olanların sayıları bulunur. Daha sonra, büyük değer, ağın net girdisi olarak kabul edilir.
Kümülatif Toplam $Net = Net_{eski} + \sum_i (X_i W_{kj})$	Her girdi kendi ağırlığıyla çarpılır ve tüm çarpımlar toplanır. Daha sonra bu değer önceki bilgilere eklenir ve ağların net girdisi bulunur.

4) Aktivasyon Fonksiyonu


Bu fonksiyon, hücreye gelen net girdiyi işler ve hücrenin o girdi için üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi, aktivasyon fonksiyonu için de farklı formülasyonlar kullanılabilir. Çok katmanlı algılayıcılar gibi bazı modeller, bu fonksiyonun türevinin alınabilir bir fonksiyon olmasını gerektirir. Bir problem için en uygun aktivasyon fonksiyonu, ağ tasarımcısı tarafından deneme yanılma yoluyla bulunabilir. Çok katmanlı algılayıcı modelleri için, genellikle aktivasyon fonksiyonu için sigmoid fonksiyonunu kullanılır.

Yapay sinir ağlarında çok sayıda aktivasyon fonksiyonu olmakla beraber yaygın olarak kullanılan bazı aktivasyon fonksiyonu türleri verilmiştir:

- a. Sigmoid Fonksiyon: Sürekli ve türevi alınabilir bir fonksiyon olması ve doğrusal olmaması nedeniyle yapay sinir ağlarında en sık kullanılan fonksiyondur. Sigmoid fonksiyonu için formül denklem (1.5) 'te verilmiştir:

$$\varphi(v) = \frac{1}{1 + \exp(-\alpha v)} \quad (1.5)$$

Bu formülde $\varphi(v)$, indüklenen yerel alan v için aktivasyon fonksiyonunu gösterir ve α , sigmoid fonksiyonunun eğim parametresidir. α parametresini değiştirerek, Şekil 1.13' te gösterildiği gibi farklı sigmoid fonksiyonları elde edebiliriz:




Şekil 1.13. Sigmoid tipli fonksiyon

Sigmoid işlevi grafiği S şeklindedir ve yapay sinir ağlarında en yaygın kullanılan aktivasyon fonksiyonudur. Doğrusal ve doğrusal olmayan davranış

arasında bir denge sergileyen, kesinlikle artan bir fonksiyon olarak tanımlanır. Sınırdaki eğim parametresi sonsuza yaklaştıkça, sigmoid fonksiyonu basitçe bir eşik fonksiyonu haline gelir, 0 veya 1 değerini alır, bir sigmoid fonksiyonu 0 ile 1 arasında sürekli değerler aralığını varsayar. Bazen aktivasyon fonksiyonunun -1 ile +1 aralığında olması arzu edilir, bu durumda aktivasyon fonksiyonu orijine göre bir asimetrik varsayar; yani, aktivasyon fonksiyonu, yerel alanın tek bir fonksiyonudur. Sigmoid tipi bir aktivasyon fonksiyonunun yukarıdaki gibi negatif değerler almasına izin vermenin bazı analitik faydaları vardır (Haykin, 1999).

- b. Doğrusal Fonksiyon: Doğrusal bir problemi çözmek amacıyla kullanılır. Şekil 1.14 doğrusal fonksiyonu göstermektedir. Ağa gelen girdiler doğrudan hücrenin çıktısı olarak kabul edilir. Doğrusal fonksiyon formülü denklemi 1.6' da verilmiştir.

$$F(Net) = Net \quad (1.6)$$




Şekil 1.14. Doğrusal fonksiyon

- c. Adım (Eşik) Fonksiyonu: Hücrenin çıktısı, gelen net girdi değerinin belirtilen eşik değerinin altında veya üstünde olmasına bağlı olarak 0

veya 1 değerini alır. Eşik fonksiyonu grafiği Şekil 1.15'te ve denklemi 1.7' de gösterildiği şekilde ifade edilir:


$$F(Net) = \begin{cases} 1, & \text{eğer } Net > \text{Eşik Değer} \\ 0, & \text{eğer } Net \leq \text{Eşik Değer} \end{cases} \quad (1.7)$$



Şekil 1.15.Adım (eşik) fonksiyonu

- d. Hiperbolik Tanjant Fonksiyonu: Yapay sinir ağlarında sık kullanılan fonksiyon tiplerinden biridir. Sigmoid fonksiyonuna benzemekle birlikte girdi değerlerinin her biri için -1 ile +1 arasında bir değer üretir. Hiperbolik tanjant fonksiyon denklemi 1.8'de, grafiği ise Şekil 1.16' da gösterilmektedir.


$$F(Net) = \frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}} \quad (1.8)$$



Şekil 1.16. Hiperbolik tanjant fonksiyonu

- e. Sinüs Fonksiyonu: Bu fonksiyon, öğrenilmesi gereken olayların sinüs fonksiyonuna göre dağılım göstermesi durumunda kullanılır. Denklem 1.9 ve Şekil 1.17’ de fonksiyona ait bilgiler verilmiştir.

$$F(Net) = \sin(Net) \quad (1.9)$$



Şekil 1.17. Sinüs fonksiyonu

5) Çıktı

Çıktı aktivasyon fonksiyonu tarafından belirlenen değerdir. Çıktı dış dünyaya veya başka bir ağa gönderilebilir Çıktı, bir YSA için sorunun çözümüdür.

1.5. Yapay Sinir Ağ Modelleri

Bir yapay sinir ağında nöronların yayılma ve aktivasyon fonksiyonları, öğrenme stratejisi ve seçilmiş öğrenme kuralları ağın modelini tanımlar. Bu amaçla birçok ağ modeli geliştirilmiştir (Yurtoğlu, 2005).

1.5.1. Basit Algılayıcı Model (Perceptron)

İlk olarak 1958'de Rosenblatt tarafından örüntü sınıflandırması için geliştirilmiştir. Bir nöronun birden fazla girdi alması ve bir çıktı üretmesi ilkesine dayanır. Çıktı değerini hesaplamak için eşik fonksiyon değeri kullanılır. Sadece doğrusal sınıflandırma yapılabilir (Fausett ve Fausett, 1994).

1.5.2. Çok Katmanlı Algılayıcılar (Multi Layer Perceptron)

Çok katmanlı algılayıcı (MLP), en yaygın olarak uygulanan sinir ağı modellerinden biridir. Çok katmanlı algılayıcı, tek katmanlı algılayıcılarla çözülemeyen pratik sorunların çözümlerini bulmak için geliştirilmiştir. Haritalama yetenekleri açısından, MLP' nin zor işlemlere yaklaşabildiğine inanılmaktadır. Bu, doğrusal olmayan dinamiklerin ve diğer fonksiyon haritalama problemlerinin çalışılmasında önemli olmuştur (Widrow ve Lehr, 1990).


XOR problemleri tek katmanlı algılayıcılar ile çözülemez. Bu noktada XOR problemlerine çözüm bulmak için çok katmanlı algılayıcılar geliştirilmiştir.

Çok katmanlı algılayıcılarda, giriş ve çıkış düğümleri arasında gizli katmanlar olarak adlandırılan bir veya daha fazla katman vardır. Çok katmanlı algılayıcılar denetimli öğrenme algoritması kullanır ve ayrıca MLP'ler gelişmiş bir Delta öğrenme kuralı biçimidir. Delta kuralı, en küçük kareler metodu kullanılarak ağın gerçek ile istenen çıktı (ağ tarafından üretilen çıktı) değeri arasındaki hata

miktarını azaltır (Widrow ve Lehr, 1990). Genelleştirilmiş Delta kuralı iki şamadan oluşur;

- İlk aşama, ileri doğru hesaplama aşamasıdır. Bu aşamada bağlantıların ağırlık değerleri sabitlenir ve girdi-çıkı setine göre şebekenin çıkışı hesaplanır.
- İkinci aşama, geriye doğru hesaplama aşamasıdır. Bu aşamada bir hata değeri ağ tarafından üretilen çıktı ile gerçek çıktı karşılaştırılarak hesaplanır. Amaç, hesaplanan hata değerini en aza indirmektir. Bu nedenle, bu hata değeri, ağırlığın değeri boyunca geriye doğru (yani, çıkış nöronlarından giriş nöronlarına doğru) yayılır. (Mehrotra ve ark., 1997)

Şekil 1.18’de MLP’ nin yapısı gösterilmiştir.



Şekil 1.18. Çok katmanlı algılayıcı ağıнын yapısı

Bir MLP 'nin çalışma adımları aşağıdaki gibidir:

- Sorunla ilgili veriler toplanarak çözüm üretilir.
- Ağ modeli belirlenir.
- Ağın öğrenme parametreleri belirlenir.
- Başlangıç rastgele ağırlık değerleri atanır.
- Seçilen değerler ağda gösterilir.
- Şebekenin çıkışı bulmak için ileri faz hesaplamaları yapılır.
- Gerçek çıktı ve istenen çıktı hata değerini hesaplamak için karşılaştırılır.
- Bağlantılar arasındaki ağırlık değerlerini değiştirmek için geriye dönük hesaplamalar yapılır.

Bu adımlar, ağ öğrenmesini tamamlayana kadar, yani gerçek ve istenen çıktı arasındaki fark belirli bir değerin altına düşene kadar tekrarlanır.

1.5.3. Öğrenme Vektör Nicelendirmesi Ağı

Öğrenme vektör nicelendirme (LVQ), 1984 yılında Kohonen tarafından geliştirilmiştir. Bir örüntü sınıflandırma yöntemidir. LVQ modelinde bir girdi katmanı, bir Kohonen katmanı ve bir çıktı katmanı vardır. Çıktı katmanında, nöronların sayısı, farklı sınıf kategorilerinin sayısı ile aynıdır. Kohonen katmanı, bu sınıfların her biri için gruplanmış bir dizi nörona sahiptir. LVQ' nun n boyutlu vektörü m boyutlu bir vektöre eşlemek için kullanıldığı söylenebilir (Fausett ve Fausett, 1994).

1.5.4. Som Ağı (Self-Organizing Map)

SOM ağı Kohonen tarafından geliştirilmiştir. Bu ağın temel özellikleri, denetimsiz öğrenmeyi kullanmasıdır. Girdi örüntüleri arasındaki ilişkiyi

haritalayarak sınıflandırma yapar. Bu ağlar bir giriş ve bir çıkış katmanından oluşur ve diğer ağlardan farklı olarak çıkış katmanını 2 boyutlu bir düzlemdir. Genelde sınıflandırma amaçlı kullanılırlar. Özellikle de beklenen çıktılarını belirlenemediği problemler için kullanılmaktadır (Carpenter ve Grossberg, 1987).

1.5.5. Uyarlanabilir Rezonans (ART) Ağı

ART ağları 1976 yılında Stephen Grossberg ve Gail Carpenter (Kriesel, 2005) tarafından geliştirilmiştir.

ART ağının girdi ve çıktı olmak üzere iki katmanı vardır. İki katman birbirleriyle tamamen bağlantılıdır ve bağlantılar ileri ve geri yöndedir. ART ağları denetimsiz öğrenme stratejisi kullanır ve karşı çoğaltma ve çift yönlü ilişkisel bellek ağları gibi diğer ağların temelini oluşturur. ART ağları, kümeleme problemleri için kullanılır. Ancak ART'nin en önemli özelliği, kullanıcının aynı kümedeki üyeler arasındaki benzerlik derecesini önceden tanımlanmış sabiti kullanarak kontrol etmesine izin vermesidir. ART ağları eğitmek için danışmansız öğrenme yöntemi kullanılır (Sağıroğlu ve ark., 2003).


1.5.6. Hopfield Ağı

Hopfield ağı, tek katmanlı ve geri bildirimli bir ağıdır. Tüm nöronlar aynı anda hem girdi hem de çıktıdır.

Bu, Hopfield ağlarının çok döngülü bir geri bildirim sistemi oluşturduğu anlamına gelir. Geri bildirim döngülerinin sayısı ve nöron sayıları aynıdır. Esasen, her bir nöronun çıkışı, bir zaman geciktirme elemanı ile diğer nöronlara geri beslenir. İki farklı Hopfield ağı türü vardır:

- Kesikli Hopfield Ağı: Bu ağlar çağrışımlı bellek olarak kullanılır.
- Sürekli Hopfield Ağı: Bu ağlar, kombinatorial optimizasyon problemlerinin çözümü için kullanılır. (Anderson ve McNeill, 1992).


Ağ mimarisinin muazzam paralellik ve kullanışlı donanım uygulaması Hopfield ağlarının en önemli avantajları arasındadır. Üç nöron içeren bir Hopfield ağının yapısı Şekil 1.19' da gösterilmiştir. Bu tek katmanlı ağda, her nöron diğer nöronlara bağlıdır, ancak hiçbir nöronun kendisi ile bir bağlantısı yoktur (Akyol, Bayhan, 2007).



Şekil 1.19. Hopfield ağı (Akyol, Bayhan, 2007)

1.5.7. Elman Ağı


Elman ağları, MLP' lerle aynı öğrenme kuralını kullanır. Bir Elman ağında; giriş, içerik, gizli ve çıkış nöronu olmak üzere 4 farklı nöron tipi vardır. Giriş ve çıkış nöronları çevre ile ilişki içindedir. Giriş nöronları dış dünyadan bilgi alır ve gizli nöronlara iletir. Çıkış nöronları, ağ tarafından üretilen çıktıyı çevreye iletir. İçerik nöronları, gizli nöronların önceki aktivite değerlerini hatırlamak için kullanılır. Bu nöronlar, önceki iterasyon değerlerini bir sonraki iterasyona girdi olarak iletmekten sorumludur. Elman ağlarında, her gizli nöron için bir içerik nöronu vardır. (Kriesel, 2005). Elman ağının yapısı Şekil 1.20'de gösterilmiştir.



Şekil 1.20. Elman ağ yapısı

1.5.8. Radyal Tabanlı Yapay Sinir Ağları (RBF)

Radyal Tabanlı Yapay Sinir Ağları 1988'de geliştirilen YSA yöntemidir. RBF' de girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katman vardır (Şekil 1.21). Girdi katmanı şebekeye giren verilerin bulunduğu katmandır. Gizli hücre katmanında ise hücreler yer alır. Temel fonksiyonların çıktıları burada hesaplanır. Çıktı katmanında ise temel fonksiyonlar arasında doğrusal bir bağıntı veya kombinasyon bulunmaya çalışılır (Aslan, 2008).




Şekil 1.21. Radyal tabanlı yapay sinir ağları (RBF)

Gauss fonksiyonu en yaygın kullanılan radyal tabanlı fonksiyonudur. RBF yapısında gizli katman ve çıktı katmanı arasında ayarlanabilir ağırlıklar mevcuttur. Karmaşık problemlere hızlı çözümler getirebilen bu ağ yapısının gizli katmanı doğrusal olmayan ve çıktı katmanı ise doğrusal özellik gösterir. RBF problem çözümleri sırasında belli bir parametrenin ayarlanmasına gereksinim duyar. Bu parametre yayılma sabitidir ve gizli katmandaki radyal tabanlı fonksiyonların merkezleri ve genişliklerini belirler. Bu sabit değer dikkatli şekilde belirlendiği zaman daha doğru sonuçlara hızlı bir şekilde ulaşmak mümkün olmaktadır (Park ve Kwon, 2017).

1.5.9. Genelleştirilmiş Regresyon Yapay Sinir Ağları (GRNN)

GRNN radyal tabanlı sinir ağına (RBF) alternatif yöntem olarak Specht (1991) tarafından geliştirilmiştir. GRNN, doğrusal olmayan regresyon teorisine dayanan bir girdi katmanı, bir örnek katmanı, bir toplama katmanı ve bir çıktı katmanından oluşan ileri beslemeli ağıdır (Şekil 1.22). Basit ve anlaşılır bir eğitim algoritmasına sahiptir. Girdi katmanında, nöron sayısı verilerin özelliklerinin sayısına, verinin boyutuna eşittir. Girdi katmanı, eğitim kalıplarını ileriye doğru hareket ettirir ve ağırlıklı bağlantılarla örnek katmanına bağlanır. Örnek katmanından elde edilen çıktı iki tip toplama nöronlarından oluşan toplama katmanını besler: payda ve pay nöronları. Toplama katmanında, örnek katmanı çıktılarının ağırlıksız toplamını hesaplamak için kullanılan yalnızca bir payda nöronu vardır. Pay nöronları, örnek katmanı çıktılarının ağırlıklı toplamını hesaplamak için kullanılır, burada ağırlık, o örnek katmanı nöronunun eğitim durumu için bağımlı değişkenin değerine eşittir. Pay nöronu sayısı çıkış sayısına eşittir. Çıktı katmanında pay nöronundan gelen değer, payda nöronundan gelen değere bölünür ve sonuç değeri elde edilir (Specht, 1991).



Şekil 1.22. Genelleştirilmiş regresyon yapay sinir ağları (GRNN)

1.5.10. Hibrit Yapay Sinir Ağları

Birden fazla ağı aynı probleme çözüm üretmek için geliştirilen sistemlere hibrit ağlar denir. Her bir ağ problemin farklı bir yönünü öğrenebilmekte ve hepsinin kararları birleştirilerek ortak bir karar oluşturulmaktadır. Genelde oluşturulan hibrit ağların performansı sistemi oluşturan diğer ağların tek tek performanslarından daha yüksektir.

Çözüm aranan problemde karar verebilmek için ağların girdi ve çıktılarının aynı olması gerekir. Ayrıca hibrit sistemlerin sadece yapay sinir ağlarından oluşması da gerekmez. İstatiksel sistemler, uzman sistemler, klasik öğrenme sistemleri de yine hibrit sistemlerin bir parçası olabilirler. Burada önemli olan bu sistemlerin de aynı girdi hakkında çözüm üretebilmeleridir. Hibrit ağların özelliklerinden birisi de hepsinin aynı örnek üzerinde karar verebilmeleridir. Ağların çıktıları sistemin çıktısını oluşturmak için girdi olarak kullanılmaktadır. Ağların birbirleriyle doğrudan ilişkileri bulunmamaktadır. Her ağ girdileri bağımsız olarak işlemekte,

diğer ağların kararlarını etkileyecek bir girişimde bulunmamaktadır. Kararların ortak değerlendirilmesinde ağların etkisi görülmemektedir (Öztemel, 2003).

1.6. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarının ait en önemli özelliklerden biri öğrenme yeteneğidir. Öğrenme; bir ağın çevre tarafından uyarılması işlemi yoluyla eğitilmesi boyunca ağırlıklarının düzenlenmesi sürecine denir. Bu öğrenme süreci üç farklı anlam ifade etmektedir (Wasserman, 1993):

- Yapay sinir ağı bulunduğu ortam tarafından uyarılır.
- Bu uyarılmanın bir sonucu olarak yapay sinir ağı, önceden belirlenmiş kurallar doğrultusunda parametrelerinde değişikliklere uğrar.
- Sinir ağı, içyapısında meydana gelen değişiklikler nedeniyle çevreye yeni bir şekilde çıktı sunar.

Bir sinir ağı için farklı öğrenme stratejileri vardır. Öğrenme sistemi ve öğrenmede kullanılacak öğrenme algoritması bu stratejilere göre değişmektedir. Genel olarak, bir YSA için üç farklı öğrenme stratejisi vardır. Bunlar;

- Danışmanlı öğrenme,
- Danışmansız öğrenme;
- Takviyeli öğrenmedir.

1.6.1. Danışmanlı Öğrenme

Aynı zamanda bir öğretmenle öğrenme olarak da adlandırılır. Bir öğretmenle öğrenme de denir. Bu stratejide çevre hakkında bilgiye sahip olan öğretmeni düşünebiliriz ve bilgi sete girdi çıktı örneklerini temsil eder. Öğretmen, giriş-çıkış seti olarak sisteme örnekler verir. Sistemin görevi, girdileri öğretmen tarafından

belirlenen çıktılarla eşlemektir. Bu şekilde olayın girdileri ve çıktıları arasındaki ilişkiler öğrenilir (Haykin, 1999). En çok tercih edilen yapay sinir ağı modeli olan çok katmanlı algılayıcılar modeli bu yöntemden faydalanmaktadır (Masters, 1993).

1.6.2. Danışmansız Öğrenme

Bu stratejide sistemin öğrenmesine yardımcı olacak bir öğretmen yoktur. Sisteme sadece giriş değerleri gösterilir. Örneklerdeki parametreler arasındaki ilişkilerin sistem tarafından öğrenilmesi beklenir. Genellikle bu strateji kümeleme problemlerinde kullanılır. (Saraç, 2004).

Günümüzde sınırlı kullanım alanları bulan ama sürekli geliştirilen bir öğrenme yöntemi olan danışmansız öğrenme yöntemi gelecekte bilgisayarların insan yardımı olmadan öğrenebileceklerini göstermektedir (Anderson ve McNeill, 1992).

1.6.3. Takviyeli Öğrenme

Bu stratejide, her giriş setinin tamamlanmasından sonra ağa mantıksal veya gerçek bir değer (veya sinyal) gönderilir. Bu değer, üretilen çıktının doğru veya yanlış olduğunu gösterir (Jain ve ark., 1996). Takviyeli öğrenme yönteminin, denetimsiz öğrenmeden daha etkili olması gerektiği söylenebilir. Çünkü ağ, sorunun çözümü için belirli bir sinyal alır. Learning Vector Quantization (LVQ) ağı, bu stratejiyi kullanan sistemlere bir örnektir (Kriesel, 2005).

1.7. Yapay Sinir Ağlarında Öğrenme Kuralları

YSA gibi öğrenme sistemlerinde, hangi öğrenme stratejisi kullanılırsa kullanılsın, öğrenme süreci bazı kurallara göre gerçekleştirilir. Öğrenme sistemlerinde kullanılan farklı öğrenme kuralları vardır. Bunlardan bazıları şu şekildedir:

1.7.1. Hebb Kuralı

Hebb kuralı ilk ve en bilinen öğrenme kuralı olup 1949 yılında Donald Hebb tarafından geliştirilmiştir. Diğer öğrenme kurallarının temelini oluşturur. Bu kurala göre; bir nöron başka bir nörondan girdi alırsa ve her iki nöron da aktifse (matematiksel olarak aynı işarete sahipse), bu nöronlar arasındaki bağlantı kuvvetlendirilmelidir (Anderson ve McNeill, 1992).

1.7.2. Hopfield Kuralı

Hebb kuralı ile benzer özelliklere sahip bu öğrenme kuralının Hebb kuralından farkı; bu kuralda, nöron bağlantılarının güçlendirilmesi veya zayıflatılması öğrenme katsayısı yardımıyla gerçekleştirilir. Beklenen çıktı ve girdiler hem aktif hem de pasif ise, ağırlık değerleri öğrenme katsayısı kadar artırılır. Aksi takdirde ağırlık değerleri öğrenme katsayısı kadar azaltılır (Kohonen ve Barna, 1987).

1.7.3. Delta Kuralı

Widrow ve Hoff tarafından geliştirilen Delta kuralı, en küçük kareler kuralı olarak (Least-Mean-Square Rule) da bilinmektedir. Delta kuralı, Hebb kuralının gelişmiş bir biçimidir. Bu kural, istenen çıktı ile gerçek çıktı arasındaki farkı azaltmak için nöron bağlantılarının ağırlık değerlerini sürekli olarak değiştirme ilkesine dayanmaktadır. Bu kural, hata karelerinin ortalamasını alıp, bu değerin en küçük olduğu çözümü bulmayı hedefler. Delta kuralı kullanımında girdi setindeki verilerin rasgele dağılmış olması önemlidir. Eğitim setinin düzgün bir sırada olması, ağırlık istenen doğruluğa ulaşmasını engelleyebilir ve ağırlık öğrenme yeteneğini zorlaştırır (Anderson ve McNeill, 1992).

1.7.4. Kohonen Kuralı

Bu kural Teuvo Kohonen tarafından geliştirilmiştir. Bu kurala göre, nöronlar ağırlıklarını değiştirmek için birbirleriyle yarışır. Yarışmadaki amaç ise bir nöron

için en büyük çıktıyı üretmek ve ağı kendisine ait ağırlığın değiştirilmesidir. En büyük çıktıyı üreten nöron, kazanan nörondur ve bağlantı ağırlıkları değiştirilir. Bu, kazanan nöronun komşu nöronlara karşı daha güçlü hale geldiği anlamına gelir. Hem kazanan nöronun hem de kendisine komşu diğer nöronların ağırlıklarının değiştirilmesine de izin verilir. Sadece kazanan nöronun çıktı üretmesine ve komşu nöronları ile birlikte ağırlıklarının değiştirilmesine izin verilir. Kohonen kuralı, danışmansız öğrenme ile eğitimini gerçekleştirir (Rojas, 1996).

1.7.5. Dereceli Azaltma (Gradient Descent) Kuralı

Bu kural Delta kuralı ile aynıdır. Delta kuralında olduğu gibi bu kural da bağlantı ağırlıklarında kullanmadan önce delta hatasını değiştirmek için transfer fonksiyonunun türevini kullanır. Bununla birlikte, ağırlık üzerinde etkili olan son değişim faktörü için öğrenme hızına dahil edilen bir katkı orantılı sabiti kullanılır. Bu kural yaygın olarak kullanılmaktadır, ancak kararlılık noktasını yavaş yakınsamaktadır (Anderson and McNeill, 1992).

1.8. Yapay Sinir Ağının Tasarımı

Bir yapay sinir ağı modeli tasarımında nöronların kullandıkları toplama ve aktivasyon fonksiyonları, öğrenme metodu, öğrenme kuralı ve algoritması tespit edilmelidir. Veri setine ve ağdan yapılması istenen uygulama alanına göre model tasarlanır. Kurulan modelin başarı oranı modelin mimarisinin doğru oluşturulması ile doğrudan ilgilidir. Yapay sinir ağ modelinin kurulmasında gerekli temel koşullar (Hawley ve ark., 1990):

- İlk olarak modelin amacının yani çıktıların belirlenmesi,
- Yapay sinir ağı modeline ait girdi değerlerinin belirlenmesi,
- Bu girdilerle ilgili veri setinin oluşturulması,

- Eğitim ve test setinin belirlenmesi ve ağı uygun olacak biçimde dönüştürülmesi,
- Ağ topolojisinin (katman sayısının, katmanlardaki nöron sayısının ve nöronların aktivasyon fonksiyonunun) belirlenmesi,
- Öğrenme algoritması ve parametrelerinin belirlenmesi,
- Ağı eğitilmesi ve test edilmesi,
- İstenilen duruma gelene kadar geçmiş adımların tekrarlanmasıdır.

1.8.1. Eğitim ve Test Setlerinin Belirlenmesi

YSA’da, ağ eğitimi için bir dizi girdi modeli ayrılır ve diğer modeller ağ performansını test etmek ve doğrulamak için kullanılır.

Eğitim örnekleminin seçilmesindeki önemli nokta, eğitim seti olarak seçilen girdi modellerinin popülasyonu ve temel yapıyı temsil etmesi gerektiğidir (Roiger ve Geats, 2003). Uygun olmayan seçim, hatalı yapılandırılmış bir ağa ve dolayısıyla düşük performansa neden olabilir.

Literatürde eğitim ve test setlerinin büyüklüklerinin belirlenmesi konusunda fikir birliği yoktur. Çoğu araştırmacı, eğitim ve test setlerini %90’a karşı %10 veya %80’e karşı %20 veya %70’e karşı %30 kuralıyla seçer (Zhang ve ark., 1998).

1.8.2. Normalizasyon

YSA’daki tüm veriler tek bir aralıkta ve birbirine benzer şekilde olmalıdır. Tüm veriler tek bir aralıkta değil ve birbirleriyle orantılı değilse, yani veriler arasındaki fark çok büyük veya küçükse, ortaya çıkan girdiler orantısız olacaktır. Verideki aşırı salınımları engellemek ve sistem performansını arttırmak için normalizasyon kullanılır. Bu nedenle, hesaplama hatalarını önlemek için verilerin belirli bir aralıkta ölçeklenmesi gerekir. Ölçeklendirme için genellikle [0,1] aralığı tercih edilir. Veri normalleştirme, eğitim süreci başlamadan önce uygulanır.

Normalizasyon işleminde farklı yöntemler kullanılır. Literatürde birçok istatistiksel normalizasyon çeşidi vardır. Bunlar; basit, minimum-maksimum, medyan, sigmoid ve istatistiksel gibi normalizasyon kuralları olabilmektedir (Jayalakshmi ve Santhakumaran, 2011; Zhang, ve ark., 1998). Bu çalışmada basit normalizasyon kullanılmıştır.

$$x = \frac{x_0}{x_{max}} \quad (1.10)$$

Denklem 1.10 da yer alan x , x_0 ve x_{max} sırasıyla normalleştirilmiş veriler, orijinal veriler ve maksimum verileri temsil etmektedir.

1.8.3. Gizli Katman Sayısı ve Nöron Sayısının Belirlenmesi

Problemin yapay sinir ağlarıyla başarılı bir şekilde çözülebilmesi için sinir ağı topolojisinin doğru belirlenmesi gerekmektedir. YSA topolojisi seçiminde giriş nöron sayısı, ağı katman sayısı, her katmandaki nöron sayısı ve çıkış nöron sayısı belirlenir. YSA topolojisinin seçimi sorunun türüne bağlıdır (Anderson ve McNeill, 1992).

Sinir ağlarındaki katman sayısı ve her katmandaki nöron sayısı, ağı performansını etkiler. Katman sayısı ve her katmandaki nöron sayısı arttıkça öğrenme düzeyi artar ve ağı çözümünü bulma süresi uzar. Bununla birlikte, katman sayısı ve her katmandaki nöron sayısı çok küçükse, ağ öğrenemez ve ortaya çıkan çıktı daha az duyarlı olacaktır. Katmanların ve nöronların sayısını belirlemek için kesin bir kural veya yöntem yoktur. Genellikle deneme yanılma yöntemi kullanılır ve ortaya çıkan ağların performansları karşılaştırılarak en uygun ağ seçilir.

Gizli katman sayısının belirlenmesinde geline nokta; birçok problem için bir gizli katman veya en fazla iki gizli katmanın kullanılmasıdır (Kaastra ve Boyd, 1996).

Gizli katmandaki nöron sayısı ile ilgili hesaplamalarda literatürde birden fazla yöntemin olduğu ve tam olarak kaç olması gerektiğine ilişkin belirli bir kural

olmadığı görülmektedir (Baily ve Thomson,1990). Bir girdi katmanı, bir gizli katman ve bir çıktı katmanından oluşan üç katmanlı bir YSA için, gizli nöron sayısının, girdi katmanındaki nöron sayısının %75'i olması gerektiğini ileri sürülmüştür. Katz, en uygun gizli nöron sayısının, girdi katmanındaki nöron sayısının 1,5 katı ile 3 katı arasında olduğunu ileri sürmektedir (Katz,1992). Doig ise gizli katmanda olması gereken nöron sayısının gizli katman sayısına göre çok daha fazla alternatife sahip olmasından dolayı uygun sayıyı belirlemek için denklem 1.11'den yararlanılabileceğini söylemiştir (Doig, 1999).

$$N_s = \frac{\frac{1}{2}(N_g + N_{\text{Ç}}) + \sqrt{N_d}}{N_b} \quad (1.11)$$

N_s : Gizli katmandaki nöron sayısı

N_g : Girdi katmanındaki nöron sayısı

$N_{\text{Ç}}$: Çıktı katmanındaki nöron sayısı

N_d : Gözlem sayısı

N_b : Katman sayısı

1.8.4. Öğrenme Algoritmasının Seçimi

Sinir ağı uygulamalarında öğrenme algoritmasının seçimi en önemli bölümdür. Ağ algoritmasının başarılı sonuç vermesini sağlayan en önemli faktör, öğrenme algoritmasının doğru seçimidir. Literatürde birçok öğrenme algoritması vardır, ancak sinir ağları için kesin bir en iyi öğrenme algoritması yoktur. Problemin özelliğine göre değişebilir (Kızılaslan, 2008).

1.8.5. Yapay Sinir Ağı Parametrelerinin Belirlenmesi

YSA modelinin oluşturulmasında bir diğer konu ise ağı parametrelerinin belirlenmesi hususudur. YSA parametrelerini; girdi ağırlıkları, momentum ve öğrenme katsayıları, toplama ve aktivasyon fonksiyonları oluşturmakta olup bu

parametrelerin doğru bir şekilde seçilmesi ağın başarısını etkilemektedir. Ağın mimarisinin oluşturulması aşamasında olduğu gibi, parametrelerin seçiminde de kesin formüller bulunmamakta ve deneme yanılma yoluyla ağa uygun parametre değerleri bulunmaya çalışılmaktadır (Öztemel, 2003).

1.8.6. Yapay Sinir Ağlarının Eğitimi ve Testi

Bir yapay sinir ağında, nöronlar arasındaki bağlantı ağırlıkları başlangıçta rastgele atanır. YSA eğitimi, girdi veri setinden istenen çıktıyı üretmek için rastgele atanan ağırlık değerlerini değiştirme işlemidir. Öğrenmenin amacı, ağ için en uygun ağırlık değerlerini belirlemek ve problem için doğru çıktıyı üretmektir. Ağırlık değerlerinin değiştirilmesi, öğrenme kurallarına göre yapılır. YSA, denemeler sonucunda doğru ağırlık değerlerini bulduğunda, bu ağ problemin diğer örnekleri için genelleme yeteneği kazanır. Ancak bazı durumlarda, ağ bir çözüme bağlanır ve ağın performansını iyileştirmek mümkün olmaz. Bu nedenle problemin çözümü için bir hata toleransı değerinin kabul edilmesi gerekmektedir. Hata tolerans değerinin altındaki herhangi bir noktada bu ağın genelleme yeteneği kazandığı ve bu çözümün kabul edilebilir olduğu söylenebilir. Tolerans değerinin altındaki kabul edilebilir çözümlere yerel çözümler denir (Öztemel, 2003).

Ağ öğrenimini göstermenin en iyi yolu bir hata grafiği çizmektir. Grafik, yineleme numarası boyunca çizilir. Belirli bir yinelemeden sonra hata daha fazla azalmaz. Bu, ağın öğrenmeyi durdurduğu ve daha iyi sonuçların bulunamayacağı anlamına gelir. Sonuçlar tatmin edici değilse, yeni çözümler bulmak için ağ topolojisi, aktivasyon işlevi veya örnek sayısı gibi bazı özellikler değiştirilebilir.

Eğitim sürecinden sonra ağın öğrenip öğrenmediğini ölçmek için test süreci başlatılır. Test süreci için eğitim süreci ile ağ tarafından görülemeyen veriler kullanılır. Test sırasında bağlantıların ağırlık değerleri değiştirilmez. Ağa test verileri gösterilir. Ağ, görünmeyen veriler için çıktı değerleri üretme amacıyla eğitim sürecinin sonunda belirlenen ağırlık değerlerini kullanır. Elde edilen çıktıların doğruluk derecesi, ağın performansı hakkında bilgi verir. Eğer test sürecinde, ağın

oluşturduğu sonuçlarla eğitim sürecindeki hatalar arasındaki fark uygun düzeyde ise, ağ kullanıma hazır demektir. Bu fark çok yüksek ise, ağırlıkların tekrar düzenlenmesi gerekir (Yakut, 2012).

1.8.7. Eğitimin Sonlandırılması

YSA'da, durdurma noktası ağ performansını önemli ölçüde etkiler. YSA' da eğitimin sonlandırılacağı noktanın seçimi hem ağın genelleştirme yeteneğini hem de ezberleme problemini etkilemektedir. Bu nedenle, ağı aşırı eğitiminden kaçınmak gerekir. Ağ eğitiminin durdurulması gereken noktayı belirlemek için iki yöntem kullanılır (Ntungu ve Boyd,1998):

- Belirtilen düzeyin altındaki hata değeri
- Belirtilen iterasyon (epoch) sayısının tamamlanması

1.8.8. Performans Ölçütünün Belirlenmesi

Yapılan tahminlerde mutlaka belirli bir hata payı oluşmakta olup bu nedenle tahmin çalışmalarının doğruluğunun ölçülmesi gerekmektedir. Performans ölçütleri, yapay sinir ağlarının öğrenme yeteneğinin ne kadar doğru olduğunu göstermek için kullanılır. Performans ölçütleri, istenilen çıktı verileri ile ağı ürettiği veriler arasındaki farkların kümülatif değerlerini hesaplamaktadır yani ağı verileri arasındaki bağıntıyı ne ölçüde öğrendiğini göstermektedir. Birden fazla performans ölçütü bulunmaktadır. Yapay sinir ağlarında en sık kullanılan performans ölçütleri Çizelge 1.5' te verilmiştir.

Çizelge 1.5. Yapay sinir ağları performans ölçütleri

$MSE = \frac{1}{T} \sum (y_t - \hat{y}_t)^2$	Hata Kareleri Ortalaması
$MAPE = \frac{1}{T} \sum \left \frac{y_t - \hat{y}_t}{y_t} \right * 100$	Ortalama Mutlak Hata Yüzdesi
$MAE = \frac{1}{T} \sum y_t - \hat{y}_t $	Ortalama Mutlak Hata
$MPE = \frac{1}{T} \sum \frac{(y_t - \hat{y}_t)}{y_t}$	Ortalama Yüzde Hata
$MSPE = \frac{1}{T} \sum \left(\frac{(y_t - \hat{y}_t)}{y_t} \right)^2$	Ortalama Yüzde Hata Kareleri
$RMSPE = \sqrt{\frac{1}{T} \sum \left(\frac{(y_t - \hat{y}_t)}{y_t} \right)^2}$	Ortalama Yüzde Hata Kareleri Kökü

Bu denklemlerde yer alan y_t , $\hat{y}_t$ ve T sırasıyla ağ çıktısını, gerçek çıktıyı ve toplam veri sayısını temsil eder.

1.9. Problemin Tanımı

Bu çalışma kapsamında halı üretimi dokuma prosesinde bulunan çağ değişim sürelerinin tahmin edildiği bir problem ele alınmıştır. Üretimi durduran bu süreç firma için önem arz etmektedir. Çağ değişim sürecinde değişim yapılan tezgâhta üretim durduğu için bu sürecin doğru planlanması ve doğru planlama için de sürecin doğru öngörülmesi gerekmektedir. Çağ değişiminde yaşanacak herhangi bir aksaklık sonraki süreçleri de etkileyerek nihai olarak termin süresini geciktirecektir. Müşteriye doğru zamanda ulaşmayan her teslimat müşteri

memnuniyet oranını etkileyerek firma için zarar oluşturabilmektedir. Bu olayların önüne geçebilmek için en doğru yöntem ile gerçeğe yakınsayan tahminler elde edebilmek firmalar açısından önemlidir.

Bu çalışma sektörde önemli paya sahip olan Gaziantep'te bulunan bir halı üretim firmasında yapılmıştır. Problemden kaçış sürecinde etkili olan değişkenlerin, firmadan alınan tezgâh raporlarından yararlanılarak; tarak numarası, tezgâh eni, renk, tezgâh bobin sayısı ve değişen bobin sayısı olmak üzere 5 girdi ve kaçış sürecini kapsayan 1 çıktıdan oluşmasına karar verilmiş ve kaçış sürecinin tahmin edilmesi için yapay sinir ağı yöntemi kullanılmıştır.

1.10. Çalışmanın Amacı

Rekabet ortamının giderek yoğunlaştığı günümüz dünyası, firmaların hızlı karar almasının ve buna bağlı olarak da doğru ve anlamlı analiz yapılmasının önemini arttırmaktadır. Firmaların süreçleri hakkında veriler toplaması tek başına fazla bir anlam ifade etmediği için bu verilerin analiz edilmesi gerekmektedir. Bu nedenle firma verimliliğini arttırmak için veriler çeşitli yöntemler ile analiz edilerek anlamlı duruma getirilebilir. Analiz sonuçları üretim, planlama, satınalma, pazarlama gibi çeşitli karar verme mekanizmaları için kullanılabilir.

Bu çalışmada kaçış süreleri tahmin edilerek sürecin öngörülmesini sağlamak ve üretim planlama ile satış birimine için önemli bir bilgi kaynağı sunmak amaçlanmaktadır. Kaçış süreleri tahmini için ise çeşitli yapay sinir ağı yöntemleri denenerek en iyi tahmin yöntemini bulmak ve klasik yöntemlere göre çok daha seri ve yüksek doğrulukta üretim optimizasyonunun yapılması amaçlanmıştır. Bu sayede üretim yapılan tezgâhta ortalama duruş süreleri tahmin edilerek üretim akışı doğru bir şekilde planlanabilecek ve zamanında tamamlanan ürünler termini gecikmeden teslim edilerek müşteri memnuniyeti sağlanabilecektir.

1.11. Çalışmanın Önemi

YSA yöntemlerinin tekstil sektöründe uygulamalarına çokça rastlandığı halde makine duruşlarının tahminlemesiyle ilgili çalışmalarda klasik yöntemlerin kullanıldığı ve çağ değişim sürelerinin tahminlemesine yönelik halı üretimi ile doğrudan ilişkilendirilecek YSA veya hibritleştirilmiş YSA çalışmalarına rastlanmamıştır. Bu yönü ile çalışmanın literatüre katkı sağlayacağı düşünülmektedir.

1.12. Çalışmanın Adımları ve Organizasyonu

1.12.1. Çalışmanın Adımları

- i. **Problem Belirlenmesi ve Verilerin Toplanması:** YSA ile tahminleme probleminin ve çalışmada kullanılacak veri setinin belirlendiği ilk adımdır.
- ii. **Uygulama Yöntemlerinin Belirlenmesi:** Uygulanacak tahmin çalışmasının hangi yöntemler kullanılarak yapılacağının karar verme sürecindeki adımdır.
- iii. **Önceki Çalışmaların İncelenmesi:** Tahminleme çalışmalarıyla ilgili olarak klasik yöntemler, yapay sinir ağı yöntemi ve duruş sürelerine ilişkin geçmiş çalışmaların incelendiği süreçtir. Literatürde yer alan, çeşitli sektörlerde yapılmış tahminleme metotlarının detaylı analiz edildiği adımdır.
- iv. **Problem Tanımlanması:** Çalışma kapsamında çözülecek problemin tanımlandığı adımdır. Problemle ilgili gerekli değişkenlerin algoritmaların ve parametrelerin belirlendiği adımdır.
- v. **YSA Modellerinin Geliştirilmesi:** Problemin çözümü için YSA parametrelerinin kod yazılımına entegre edildiği adımdır.
- vi. **Önerilen Yaklaşımların Kıyaslanması:** YSA yöntemiyle denenen dört farklı modelin kıyaslandığı adımdır.

- vii. ***Sonuçların Analiz Edilmesi:*** Problemin çözümünden elde edilen tüm analiz sonuçlarının karşılaştırılarak en uygun yöntemin belirlendiği ve ilerideki çalışmalar için önerilerin sunulduğu son adımdır.

1.12.2. Çalışmanın Organizasyonu

Çalışmanın ikinci bölümünde, çeşitli sektörlerde yapay sinir ağları yöntemleri ile yapılmış önceki çalışmalara yer verilmiştir. Üçüncü bölümde, çalışmanın yapıldığı firmayla ilgi, çalışmada kullanılan veriler ve verilerin düzenlenmesi hakkında bilgiler verilmiş olup analizde uygulanacak yöntemler ve parametreleri açıklanmıştır. Dördüncü bölümde, geliştirilen modeller için elde edilen bulgular ve analizlere yer verilmiştir. Son bölümde elde edilen sonuçlar değerlendirilerek gelecekteki çalışmalar için yapılacak önerilere yer verilmiştir.

2. LİTERATÜR TARAMASI

Literatür araştırması kapsamında ilk olarak tüm alanlar için tahminleme, daha sonra süre tahminleri ve son olarak tekstil sektörü ile ilgili tahminleme için kullanılan YSA yöntemi çalışmaları kronolojik sıraya göre gruplandırılarak detaylı olarak incelenmiştir.

2.1. Yapay Sinir Ağları ile Tahminleme için Literatür Taraması

Luxhoj ve ark. (1996) aylık toplam satışları tahmin etmek için hibrit bir sinir ağı modeli üzerinde çalışmıştır. Bu modelde, ekonometrik modellerin yapısal özelliklerini sinir ağlarının doğrusal olmayan örnek tanıma özellikleriyle birleştirilerek hibrit bir modelleme oluşturulmuştur. Model, tüketim malları üreten bir Danimarka firmasının gerçek satış tahmini problemi ile test edilmiş olup sonuçlar, önerilen hibrit modelin, şirket tarafından kullanılan mevcut kalitatif yaklaşıma kıyasla MAPE değerinde %2,3'lük bir azalma sağladığını göstermiştir.

Scholkopf ve ark. (1997), Destek Vektör Makineleri (SVM) modelini bir Gauss çekirdeği, hata geri yayımlı bir hibrit sistem ve el yazısı rakamları tanıma doğruluğu açısından Radyal Temel Fonksiyonlar (RBF) makinesi ile karşılaştırmıştır. SVM modelinin üstün pratik uygulamaya sahip olduğu gösterilmiştir.

Markham ve Rakes (1998), basit doğrusal regresyon ve YSA'nın doğruluğunu, farklı örneklem boyutu ve hatanın varyansı açısından incelemiştir. Ortalama karekök (RMS) değeri performans göstergesi olarak kullanılmıştır. Örneklem büyüklüğü ve varyans değişkenlerinin regresyon analizi ve YSA yönteminin performansı açısından anlamlı olduğu sonucuna varılmıştır. Her iki teknik de büyük bir örneklem boyutu ve daha düşük varyans seviyeleri ile daha iyi performans göstermiştir.

Lee ve Shaw (2000), akış tipi çizelgeleme probleminin çözümü için iki aşamalı YSA modeli önermiştir. Yapay sinir ağı belirli örnekler kullanılarak eğitilmiş ve sistem değişik zamanlarda değişik kombinasyonlar halinde gelen işlerin sıralanması için gerçek zamanlı kararlar oluşturmıştır. YSA yöntemi ile geleneksel yöntemlere göre daha kısa hesaplama süresinde daha iyi sonuçlar elde edilmiştir. Genetik algoritmalar ile kombine edildiğinde ise hesaplama süresi ise kısalmış olup çözüm kalitesi daha da artmıştır.

Zhang ve ark. (2001) doğrusal olmayan zaman serileri tahmini için yapay sinir ağlarının bir simülasyon çalışmasını incelemiştir. Bu çalışmada, giriş düğümleri, gizli düğümler ve örneklem büyüklüğü olan üç temel değişkenin etkilerini incelediler. Giriş düğümlerinin sayısının gizli düğümlerin sayısından daha önemli olduğu ve büyük bir örnek boyutunun aşırı uyum sorununu hafifletmek için önemli olduğu sonucuna varılmıştır.

Fonseca ve Navarrese (2002), atölye tipi çizelgeleme problemi için ileri beslemeli, çok katmanlı yapay sinir ağı modeli önermişlerdir. Eş zamanlı işlem gören siparişler için sipariştan teslimat kadar geçen süre tahmini sonucu gerçek veriler kabul edilebilir seviyededir. Akış süreleri ve sıralamalar da model sonucu doğru şekilde belirlenebilmiştir.

Zhang ve Qi (2005), zaman serilerinin hem mevsimsel hem de trend modelleriyle nasıl etkili bir şekilde modelleneyeceği konusunu incelemiştir. Mevsimsizleştirme ve trendden uzaklaşmayı içeren veri ön işlemenin etkililiğini incelediler. Simülasyon ve gerçek veriler incelenmiş ve karşılaştırmak için Box-Jenkins mevsimsel ARIMA modeli kullanılmıştır. Sonuçlar, sinir ağlarının, ham verilerin herhangi bir ön işleme tabi tutulmasına gerek kalmadan mevsimsel ve trend değişimlerini etkili bir şekilde yakalayabildiğini ve trendin azalması ve mevsimsizleştirmenin tahmin hatalarını önemli ölçüde azaltabileceğini gösterdi.

Azadeh ve ark. (2007), sinir ağı, zaman serileri ve ANOVA'nın entegrasyonu yoluyla elektrik tüketimini tahmin etmeyi incelemiştir. İlk adım olarak veriler, çıktıyı artırmak için hareketli ortalama yöntemi kullanılarak zaman serileri

ile önceden işlenmiş daha sonra YSA yöntemi uygulanmıştır. Bu adımdan sonra YSA, regresyon ve gerçek verileri karşılaştırmak için ANOVA uygulanmıştır. YSA yönteminin daha yüksek tahmin doğruluğuna sahip olduğu sonucuna varılmıştır.

Pour ve ark. (2008), önerdikleri YSA modelinin performansını, hibrit yöntem, MLP, genelleştirilmiş regresyon sinir ağı (GRNN) ve Elman tekrarlayan sinir ağı (RNN) gibi farklı YSA modelleriyle karşılaştırmıştır. Bu çalışmada, önerilen hibrit yöntemin diğerlerinden daha iyi performans gösterdiği sonucuna ulaşılmıştır.

Caputo ve Pelagagge (2008), çalışmalarında siparişe göre üretim sistemlerinde büyük ölçekli ve karmaşık şekilli basınçlı kapların üretim maliyetini tahmin etmek için yapay sinir ağları ve parametrik yöntemler arasında bir karşılaştırma yapmışlardır. Parametrik yöntemlerle hata tahmini %12 olarak bulunur iken, YSA yaklaşımı ile hata yüzdesi %9 olarak bulunmuştur. YSA yönteminin, parametrik yöntemlere göre daha uygun olduğu sonucuna varılmıştır.

Efendigil ve ark. (2009), çok seviyeli bir tedarik zinciri yapısında talep tahmini üzerine çalışmıştır. Bu çalışmanın amacı, yapay zekâ ile oluşturulmuş yeni bir tahmin modeli geliştirmek olup bu yeni geliştirilen model, YSA ve uyarlanabilir ağ tabanlı bulanık çıkarım sisteminin (ANFIS) karşılaştırmasını içermektedir. Performans göstergeleri olarak MAPE ve MSE kullanılmış ve sonuçlar önerilen modelin YSA yapısından daha iyi performans göstermiştir.

Konar (2010), çalışmasında Boeing firmasının B-737-300 tipi uçağının hız ve yakıt problemlerini incelemek amacıyla ANFIS, MLP, RBF ve GRNN yöntemlerini kullanarak farklı modeller oluşturmuştur. Modellerden elde edilen sonuçların karşılaştırmasında yakıt miktarının ayarlanmasında RBF modelinin, hız miktarının ayarlanmasında ANFIS modelinin, hız ve yakıt miktarının birlikte ayarlanmasında ise GRNN modelinin öne çıktığı gözlemlenmiştir. MLP modelleriyle de diğer modeller kadar olmasa da tatmin edici sonuçlar elde edilmiştir.

Khashei ve Bijari (2011), YSA ve ARIMA modellerini birleştiren yeni bir hibrit model kullanarak bir zaman serisi tahmini üzerinde çalışmışlardır. Bu modelin

amacı YSA modelinin sınırlamalarını azaltmak ve daha doğru tahmin sonuçları elde etmektir. Bu modelde, verilerdeki doğrusal yapıyı belirlemek için ARIMA kullanılmış ve temeldeki veri oluşturma sürecini yakalamak ve geleceği tahmin etmek için YSA modeli kullanılmıştır. Bu yeni model, üç gerçek veri setine uygulanmış ve önerilen modelin ayrı ayrı kullanılan her modelden daha iyi performans gösterdiği sonucuna ulaşılmıştır.

Wang ve ark. (2011) 5500 gözleme sahip kredi skorlama problemi için lojistik regresyon analizi, karar ağacı, YSA ve destek vektör makineleri ile elde edilen sonuçları karşılaştırmışlardır. Bu yöntemlerin sonucunda en iyi performansın YSA modellerine ait olduğu görülmüştür.

Oreski ve ark. (2012) ise bu problem için YSA ve genetik algoritma ile hibrit yöntem kullanılan YSA modellerini incelemişlerdir. Hibrit yönteminin daha başarılı olduğu sonucuna ulaşılmıştır.

Gümüş ve ark. (2013), bir drenaj havzası üzerindeki yağış-akış ilişkisinin modellenmesinde, yağış-akış ilişkisini yapay sinir ağları yöntemlerinden olan ileri beslemeli geri yayılım sinir ağı, genelleştirilmiş regresyon yapay sinir ağı ve radyal tabanlı yapay sinir ağı ile araştırmışlardır. Elde edilen sonuçlar klasik bir yöntem olan çoklu doğrusal regresyon yöntemi ile karşılaştırılmıştır. Yeni akım değerlerinin tahmin edildiği bu çalışma sonucunda tüm yapay sinir ağı yöntemlerinin çoklu doğrusal regresyon yöntemine göre daha iyi sonuç verdiği görülmüş olup radyal tabanlı yapay sinir ağı yöntemiyle tahmin edilen değerlerin diğer yapay sinir ağı yöntemleriyle tahmin edilen değerlere göre gözlenen akım değerlerine daha iyi yakınsandığı belirlenmiştir.

Soydaner (2014), kredi skorlama problemi için ilk olarak klasik yapay sinir ağları modelleri oluşturmuş ve belirlenen en iyi model, test verisi üzerinde %78 doğruluk oranı ve en düşük MSE ile Levenberg - Marquardt algoritmasıyla olmuştur. Daha sonra YSA'ların hibritleştirilmesi yoluna gidilmiş ve ağların eğitiminde genetik algoritmalar kullanılmış olup oluşturulan hibrit YSA modelleri ile en iyisi test verisi üzerinde %86,8'lik bir doğruluk oranına ulaşılmış ayrıca kredi skorlama

modellerinde sık kullanılan lojistik regresyon modeli oluşturulmuş ve bu modelin performansı da %77,8 olarak elde edilmiştir. Son olarak, hibrit yapay sinir ağları, klasik yapay sinir ağları ve lojistik regresyon karşılaştırılmıştır. Araştırma sonucunda yapay sinir ağları modelinin lojistik regresyon analizinden daha iyi ve ağ hibritleştirildiğinde diğer iki modelden de daha da iyi sonuçlar elde edilmiştir.

Konate' ve ark. (2014), Zhenjing petrol sahası verilerinde gözenekliliği modellemesi üzerine çalışmış olup çalışmada GRNN ve ileri beslemeli geri yayılım sinir ağını analiz etmiş ve karşılaştırmışlardır. Sonuç olarak GRNN, gözenekliliği tahmin etmede ileri beslemeli geri yayılım sinir ağından daha iyi tahmin doğruluğu sağlamıştır.

Moretti ve ark. (2015), YSA ve basit istatistiksel yaklaşımı birleştiren karma bir model kullanarak kentsel trafik akışı tahminini incelemiştir. Önerilen yaklaşım, üç farklı gerçek cadde sınıfı üzerinde test edilmiş ve bu çalışmanın sonunda, bu yeni hibrit modelin YSA ve istatistiksel yöntemden daha iyi performans gösterdiği ortaya çıkmıştır.

Mombeini ve Chamzini (2015), çalışmalarında 1990 ile 2008 yılları arasındaki aylık altın verilerini içeren altın fiyatı tahmini için YSA ve ARIMA modellerini kullanmışlardır. Geliştirilen farklı modellerin performanslarını değerlendirmek için R^2 , RMSE ve MAE performans ölçütleri kullanılmıştır. Bu ölçütler göz önünde bulundurularak karşılaştırma yapıldığında YSA modelinin ARIMA modelinden daha iyi performans gösterdiği sonucuna ulaşmışlardır.

Hocaoğlu ve ark. (2015), yük tahminini için YSA ve regresyon yöntemlerini birleştiren hibrit yaklaşımını kullanmışlardır. Öncelikle bu çalışmada yapay sinir ağları ve çoklu regresyon analizi ile tahmin yapılmış daha sonra regresyon analizinde elde edilen sonuçlar YSA' da uygulanarak hibrit bir sistem oluşturulmuştur. Elde edilen hata sonuçları karşılaştırıldığında ise hibrit sistemin çıktılarının gerçek değerlere daha yakın olduğu sonucuna varılmıştır.

Ünal ve ark. (2016), toprak penetrasyon direncini tahmin etmek amacıyla üç farklı yapay sinir ağı yöntemini kullanmışlardır. Çalışmada 1603 verinin, %24'ü test,

%76'sı eğitim için kullanılmıştır. Toprak penetrasyon direnci; genelleştirilmiş regresyon sinir ağı (GRNN), çok katmanlı algılayıcı (MLP) ve radyal temelli fonksiyonlar (RBF) yöntemleri kullanılarak tahmin edilmeye çalışılmış olup performans ölçütü olarak MSE, RMSE ve MAE değerleri hesaplanmıştır. Sonuç olarak RBF yönteminin gerçek değerlere yakınsama durumunun diğer yöntemlere göre daha iyi olduğu tespit edilmiştir.

Pektaş (2018), petrol endüstrisinde sıvı oranının tespit edilmesi için yapay zekâ algoritmalarını kullanmıştır. Geliştirdiği kNN-GRNN algoritmasında kNN algoritmasını GRNN algoritmasının çalışması için sınıflandırma işlevi için kullanmıştır. Algoritmaların ve korelasyonların başarılarını karşılaştırmak için R^2 ve MAPE değerleri hesaplanmış ve geliştirilen algoritmanın, genel performansta, 0.95 korelasyon katsayısı ve %18 ortalama mutlak yüzdelik hata ile en başarılı model olduğu tespit edilmiştir.

Chen ve Wang (2018), iç mekân konumlandırma için GRNN modelini kullanmışlardır. Çevresel değişikliklere karşı yerleştirme sağlamlığını geliştirmek için k-en yakın komşu (KNN) yöntemini benimseyen filtreleme şeması yerleştirme modülüne yerleştirilmiştir. Çalışma sonucunda hem yerleştirme doğruluğu hem de sağlamlığı açısından GRNN modelinin KNN veya geri yayılım sinir ağına dayalı konumlandırma yöntemlerinden daha iyi performans gösterdiği tespit edilmiştir.

Kılıç (2019), imalat süreçleri sorunlardan biri olan geri esneme miktarının tahmini üzerine çalışmış ve çalışmada YSA ve Regresyon modelleri kullanılmış çalışma sonunda da bu modellerin karşılaştırması yapılmıştır. Çalışma sonucunda, YSA modellerinde uygun parametre seçiminin oldukça önemli olduğu ve YSA model sonuçlarının, Regresyon model sonuçlarından daha başarılı tahminler yaptığı belirlenmiştir.

2.2. YSA ile Süre Tahminleme için Literatür Taraması

Lee ve Kim (1993), Hill ve Remus (1994), Statake (1994) yapay sinir ağları ile çizelgeleme üzerine çalışmışlardır. Hibrit yapay sinir ağı, ileri beslemeli geri

yayımlı ağlar, Hopfield ağı, Boltzmann makine mekanizması gibi farklı yapay sinir ağı modellerini kullanarak işin çevrim zamanını azaltmayı bunun sonucunda en erken teslim zamanını bulmayı hedeflemişlerdir.

Sabuncuoğlu ve Gürgün (1996), tek makinalı atölye sisteminde ortalama gecikme ve en kısa çevrim zamanı problemi için algoritmik ve yapay sinir ağı modeli olan Hopfield ağı yaklaşımlarını birleştirerek çözüm önerisinde bulunmuşlardır. Ağın performansı, çeşitli deneysel koşullar altında mevcut programlama algoritmaları ile karşılaştırılır. Önerilen ağın performansı atölye iş planlamasının seçilen problemlerinin çoğu için optimum çözümleri sunmuştur.

Jack ve Andi (2002), dönen makinelerdeki arızaları tespit etmek için SVM modelleri kullanmıştır. Hem SVM hem de YSA sınıflandırıcıları karşılaştırılmış ve her iki tekniğin performansını artırmak için genetik algoritmaya dayalı seçim süreci uygulanmıştır.

Güngör (2007), çalışmasında talaşlı imalat yapan bir işletmede üretim hattındaki makinelerde oluşabilecek arızaların tahmin edilebilmesi için ileri beslemeli çok katmanlı yapay sinir ağı modeli kullanmıştır. Makinelerin ne zaman arızalanabileceğini önceden belirleyerek önleyici bakım uygulaması için çalışan makinelerin arızaları ile ilgili geçmiş veriler incelenerek makine arızaları arasında geçen süre yapay sinir ağı kullanılarak tahmin edilmeye çalışılmıştır. Arıza kayıtlarından oluşan veri setinin %80'ı eğitim, %20'si test için ayrılmıştır. Yapay sinir ağı modelinin eğitilmesinde geri yayılım algoritması, aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmış olup ağın eğitimi için öğrenme oranı 0,01 ve momentum katsayısı ise 0,8 olarak belirlenmiştir. Performans değerleri, eğitim ve test veri setleri için gözlemlenerek ve en iyi sonuca ulaşmaya çalışılmıştır.

Li ve ark. (2007), paralel kaynakların tamamlanma zamanının tahmin edilmesinde geri yayımlı yapay sinir ağları ile genetik algoritmanın birleşiminden oluşan hibrit bir model üzerine çalışmışlardır. Performans ölçütü olarak MSE değeri kullanılmıştır. Çalışma sonucunda hibrit modelin geri yayımlı yapay sinir ağları

modeline göre üretim süresini tahmin etmede daha etkili ve doğru olduğuna ulaşılmıştır.

Sridhar ve ark. (2009), çalışmalarında ABD'de ulusal, bölgesel ve havalimanı bazında uçuş gecikme ve iptallerini modelleme üzerine çalışmışlardır. Çalışmada çeşitli YSA modelleri ile geleneksel lineer regresyon modellerinin performansını karşılaştırmışlardır. Sonuç olarak doğrusal regresyon yöntemleri ile ortalama %75, YSA ile %80 oranında başarı ile uçuş gecikme tahmininde bulunulmuştur.

Kepekçi (2011), açık işletme kamyonları duruş sürelerinin analizi üzerine çalışmıştır. Çalışmada kamyonlar taşıdıkları malzeme ve markalarına göre gruplandırılarak veri setinde kamyonların duruş tipleri ve süreleri aylık olarak düzenlenmiştir. Bu veri setinde zaman serisi analizleri üzerine çalışılmış olup elde edilen tahmin modelleri gerçek değerler ile karşılaştırılarak modelin %95 güven aralığında kabul edilebilir sonuçlar verdiği görülmüştür. Çalışmada en uygun zaman serisi modellerinin mevsimsel ARIMA ve mevsimsel olmayan ARIMA modellerinin en iyi öngörü verdiği bulunmuştur.

Kandırılmaz ve ark. (2014), Türkiye'nin aylık güneşlenme sürelerinin tahmin edilmesi üzerine çalışmış tahmin süreçlerinde GRNN, MLP ve RBF olmak üzere üç farklı YSA modelini kullanmışlardır. Veri setinde ilk 21 yıla ait veriler eğitim için son 6 yıla ait veriler ise test için kullanılmıştır. MAE ve RMSE istatistiksel göstergeleri, GRNN ve MLP modellerinin RBF modelinden daha iyi sonuçlar ürettiğini ve aylık ortalama güneşlenme sürelerinin tahmininde güvenle kullanılabileceğini göstermiştir.

Demir (2016), çalışmasında uçuş gecikmelerinin tahmin edilebilmesi için çok katmanlı, geri beslemeli yapay sinir ağıları kullanmıştır. Veri seti %80 eğitim, %20 test olarak ayrılmıştır. Yapay sinir ağı modeli ile uçuşlardaki kalkış gecikmeleri bütün veri kullanıldığında genel ortalama %93, zamanında ve gecikmeli uçuşlar dengeli bir şekilde zaman pencerelerine parçalanarak kullanıldığında genel ortalama %96'ya kadar ulaşan bir başarı elde edilmiştir.

Peško ve ark. (2017), çalışmalarında inşaat projelerinde maliyet ve süre tahmini için YSA ve SVM modellerini kullanmışlardır. Çalışmada iş süresinin tahmin edilmesinin daha zor olduğu belirtilmiştir. En iyi MAPE; SVM modeli için %22,77 olarak bulunurken ve YSA için %26,26 olarak bulunmuştur.

Aktaş ve Aydın (2018), talaşlı imalat sektöründe üretim performansının zaman serisi analizi ile tahmini üzerine çalışmışlardır. AR ve ARIMA yöntemlerini kullanmışlar ve bu yöntemler sonucu değerler karşılaştırılarak en uygun model seçilmiş ve seçilen model kullanılarak gerçek değerlere yakın tahmin değerlerine ulaşılmıştır. Değerinin üretim miktarı, üretim tonajı, üretilen parça başı ağırlık, kalıp revizyon süresi ve bakım arıza süresi gibi üretim performansı değerlerinin her biri için polinom regresyon yöntemi ile analizi yapıp model oluşturulmuş ve tahminleme yapılmıştır. Performans ölçütü olarak MSE, RMSE ve MAPE değerleri hesaplanmıştır.

Sütçü (2018), kaynaklı imalat operasyon süreleri tahmini için yapay sinir ağı modelini kullanmıştır. Yapay sinir ağında verilerin %70'i eğitim, %15'i değerlendirme, %15'i ise test aşamasında rassal olarak kullanılmıştır. Performans kriteri olarak MSE ve R^2 değerlendirilerek sonuca ulaşılmıştır. Çalışmada ilk olarak tüm veriler kullanılarak ağ modellenmiş performans kriterlerinde istenen sonuçlara ulaşılmadığı için veri setinde gruplandırılma yapılmıştır. Gruplandırma ile modelden daha tutarlı sonuçlar elde edildiği gözlemlenmiştir.

Taşyürek ve Çelik (2020), akıllı durak sistemindeki araç seyahat sürelerinin hibrit YSA kullanılarak tahmin edilmesi üzerine çalışmışlardır. Hibrit YSA modeli birden fazla yapay sinir ağı modelinin çıktılarını ortaklaşa değerlendirilmiştir. 800 adet farklı otobüs hattının GPS verisi kullanılan YSA algoritmasının sonuçları lineer regresyon yöntemi sonuçları ile RMSE değerine göre karşılaştırılmıştır. Sonuçlar önerilen hibrit YSA yaklaşımının lineer regresyon yaklaşımına göre daha doğru sonuçlar verdiğini göstermiştir. Çalışma neticesinde geliştirilen hibrit YSA modelini kullanan mobil ve web uygulaması geliştirilmiş ve bu uygulama ile yolcular akıllı

duraklardaki kare kodları kullanıp sisteme bağlanarak tahmini otobüs geliş sürelerini takip edebilecekleri bildirilmiştir.

2.3. Tekstil ve Halı Sektöründe Tahminleme için Literatür Taraması

Meriç ve Özkal (2002), döşemelik kumaş üreten bir dokuma işletmesinde iplik kopuşlarını analiz etmişler ve üretim esnasında oluşan duruşları ve mekanik arızaları incelemişlerdir. Çalışma sonucunda mekanik arızaların, atkı ve çözgü kopuşlarının ve diğer nedenlerle ortaya çıkan duruşların fazla olmasının makinenin fiili çalışma süresini azalttığı, duruş süresini arttırdığı dolayısıyla randımanı düşürdüğüne ulaşılmıştır. Yapılan çalışma sonucu düşük randımana sebep olan en önemli faktörün yüksek oranda atkı kopuşları olduğu tespit edilmiştir.

Gharehaghaji ve ark. (2007), ipliğin gerilme özelliklerini tahmin etmek için YSA modelleri ve çoklu regresyon analizi kullanmıştır. Bu yöntemlerin her ikisini de inceleyerek YSA'nın daha doğru sonuçlar verdiğini belirlemişlerdir.

Özyirmidokuz (2009), çalışmasında halı imalat sürecini ve ürün kalitesini iyileştirmek amacıyla veri madenciliği uygulamaları yapmıştır. Ürün hata ve makine duruş verilerini ayrı ayrı modellemiş ve halı hatalarının ve makine duruşlarının nedenlerini bilgi kazancı tekniği ile standartlaştırmıştır. Veri tahmininde, karar ağaçları ve sinir ağları modelleri kullanılmış ve modellerin çıktıları karşılaştırılarak değerlendirme yapılmıştır. Karar ağacının doğruluk oranı %74,44 iken, yapay sinir ağı modeli doğruluk oranı %99,243 olarak tespit edilmiştir. Yapay sinir ağı modelinde ise radyal temelli fonksiyon ağları yöntemi kullanılmıştır. Çalışma sonunda YSA' nın benzer çalışmalar için klasik istatistiksel yöntemlere iyi bir alternatif olabileceği söylenmiştir.

Admuthe ve Apte (2010), YSA ve ANFIS modellerini pamuk iplik özelliklerini tahminleme amacıyla kullanmışlardır. Regresyon metotları gibi YSA yönteminin de elyaf ile iplik arasında kesin bir ilişki belirleyemediği için yeni bir hibrit teknik olan ANFIS modelinin iplik özelliklerini tahmin etmedeki

uygulanabilirliğini analiz etmişlerdir. Sonuç olarak, ANFIS modelinin YSA modeline göre çok daha iyi sonuç verdiği tespit edilmiştir.

Guo ve ark. (2011), halı dokuma tezgâhında akıllı çağlık üzerinde çalışmıştır. Akıllı çağlığın, çalışanları çağlıktan uzak tutan, üretim kazalarını önleyen ve işçi güvenliğini sağlarken maliyet artırıcı faydaları azaltan otomasyonu gerçekleştirdiğini gözlemlemişlerdir. Halı ipliklerinin depolama ünitesinden dokuma tezgâhına iletilmesini sağlayan akıllı çağlık, farklı ipliklerin kullanım miktarlarını farklı siparişlere göre otomatik olarak analiz edebilmekte, dokuma tezgâhına daha makul ikmaller yapabilmekte ve iplikleri kullanılmadan önce hazırlayabilmektedir. İplikten en iyi şekilde yararlanan ve üretim verimliliğini artıran bir üründür. Bu sayede iplikleri değiştirmek için zaman ve işçilikten tasarruf edildiğini tespit etmişlerdir. Çalışmada, geleneksel çerçeveli çağlığın geriye doğru bir üretim modu olduğunu, akıllı çağlığın ise temel yapısı ve kontrol sistemi pratik fonksiyon gereksinimleri ve özel iş görev analizine dayalı olarak tasarlanmış ve ayrıntılı olarak araştırılmış yeni bir model olduğunu söylemektedirler.

Bo (2012), rotorlu pamuk ipliğinin işlem parametrelerini tahminlemede çok katmanlı algılayıcı (MLP) sinir ağı yöntemini kullanmıştır. Modelin sonuçlarını değerlendirmek için modelin sinir ağı tahmin değerleri hesaplanmış ve gerçek çıktı değerleri ile karşılaştırılmıştır. Performans ölçütleri için MSE, MAE ve MAPE değerleri kullanılmış olup geri yayımlı yapay sinir ağı modelinin sonuçları iyi tahmin ettiği belirtilmiştir.

She ve ark. (2014), akıllı çağlık çoklu robot kontrol sistemi üzerinde araştırma yapmışlardır. CAN veri yoluna dayalı akıllı çağlık için Multi-robot'un dağıtılmış kontrol sistemini (DCS), merkezi yönetim ve dağıtılmış kontrol ilkesine dayanan sistem tasarlamışlardır. Robot teknolojisi ve saha ekipmanlarının gelişmesi, insan gücü maliyetinin ve üretim maliyetlerinin artması ile robot teknolojisinin tekstil endüstrisinde yaygın olarak kullanıldığını belirtmişlerdir.

Türker (2017), ileri yayımlı geri beslemeli yapay sinir ağı (YSA) modeli ile 29 pamuklu ve 49 polyester numuneden oluşturulmuş iki farklı kumaş gurubunu

test etmiştir. Her numune kendi içinde eğitim ve test guruplarına ayrılmıştır. Hem pamuklu hem de polyester grubu için lineer regresyon sonuçları da elde edilmiştir. Pamuk numuneler için kumaş ağırlığı, kalınlığı, atkı ve çözgü kopma mukavemetini incelemiş olup polyester numuneler için hava ve su geçirgenliği değerlerini incelemiştir. Tüm numunelerde yapay sinir ağı değerleri lineer regresyon değerlerinden daha iyi sonuç göstermiştir.

Çot (2019), bir halı firmasına ait iplik üretim sürecinde kıvrımlılık, mukavemet ve uzama gibi çıktı parametrelerin farklı YSA modelleri ile tahminlemesi üzerine çalışmıştır. Çalışmada iplik üretim parametrelerinden on beş girdi parametresi içerisinde ipliğin mukavemet, uzama ve kıvrımlılık çıktı parametrelerine en fazla bağımlı olanların seçilmesi için regresyon analizi yapılmış ve 6 girdi parametresi belirlenmiştir. Belirlenen veri seti tahminlemesi için ileri kademeli geri yayılım (Cascade) ağı, ileri beslemeli geri yayılım ağı ve Elman ağı kullanılmıştır. YSA modelleri performans ölçütlerinden R^2 , MSE, MAPE, MAE, RMSE, MSPE, MPE değerlerine göre karşılaştırılmıştır. Her YSA modeli için üçer adet en iyi sonucu veren modeller belirlenmiş ve tahmin değerleri ile gerçek değerler arası doğruluk oranları için t testi yapılmıştır. Sonuç olarak performans değerlerinin ileri beslemeli geri yayılım ağ modelinde, Elman ağı ve Cascade ağı modellerine göre biraz daha iyi sonuçlar verdiği tespit edilmiştir.

Seyam (2019) yaptığı çalışmada akıllı çağlığın, çağlıktaki renk düzenlemesinde insan hatasını, çağlığın yüklenmesindeki duruş süresini, paketlerin geri sarılması ve sarıcı ihtiyacını ortadan kaldırdığını ve geleneksel çağlığa göre daha küçük olması nedeniyle israfı azalttığını belirtmiştir.

Gülyeşil (2019), halı üretiminde kullanılan hammaddelerden biri olan jütün tüketim tahmini üzerine çalışmıştır. Çalışmasında YSA modeli ile regresyon analizini karşılaştırmıştır. Modelde 246 veri kullanılmış olup %70'i eğitim, %15' değerlendirme, %15'i test verisi olarak değerlendirilmiştir. Veri seti min-maks yöntemi ile normalize edilerek modelde kullanılmıştır. Çeşitli parametrelerin değiştirilmesi sonucu deneme yanılma yoluyla oluşturulan YSA modelleri MSE ve

R^2 performans ölçütlerine göre değerlendirilerek 0.01 MSE ve 0.85 R^2 ile en iyi sonuca ulaşılırken Çoklu doğrusal regresyon analiziyle 0.12 MSE ve 0.72 R^2 değerleri bulunmuştur. Performans ölçütleri dikkate alındığında YSA'nın regresyon analizine göre daha başarılı olduğu ve YSA modeli çıktılarının gerçek değerlere daha yakın olduğu sonucuna varılmaktadır.

Turaç (2020), ihracat rakamları tahmininde YSA modelini kullanmıştır. Deneme sonucu elde edilen modeller R^2 performans kriterlerine göre değerlendirilmiştir. Veri seti %81 eğitim %19 test verisi olarak ayrılmıştır. Türkiye toplam ihracat tahmini için modelin R^2 değeri 0,95 olarak bulunmuş olup ihracat miktarı tahmininde YSA yönteminin performansı başarılı bulunmuştur.

2.4. Önceki Çalışmaların Değerlendirilmesi

Literatür taraması daha önce de belirtildiği üzere tüm sektörler için YSA çalışmaları, süre tahminleme problemleri için YSA çalışmaları ve tekstil-halı sektöründe YSA çalışmalarına göre gruplandırılarak incelenmiştir.

YSA yöntemlerinin ayrı ayrı süre tahminlemede ve tekstil sektöründe uygulamalarına çokça rastlandığı halde doğrudan halı üretimi ile ilişkilendirilecek çağ değişim sürelerinin tahminlemesine yönelik çalışmaya rastlanmamıştır.

Önceki çalışmalar incelendiğinde ele alınan problemlere ait YSA ile çözüm yöntemleri için farklı modellerden yararlanılmıştır. Bunlar; Destek Vektör Makineleri (SVM), Radyal Temel Fonksiyonlar (RBF), zaman serileri için Box-Jenkins mevsimsel ARIMA modeli, MLP, GRNN, Elman tekrarlayan sinir ağı (RNN), ANFIS ve hibrit sinir ağlarıdır. Özellikle son yıllarda yapılan çalışmalar dikkate alındığında hibrit sinir ağlarının kullanımında artış olduğu gözlemlenmektedir. Bu artış, hibrit ağların performansının genel olarak sistemi oluşturan diğer ağların tek tek performanslarından daha yüksek olmasından kaynaklanmaktadır. Ayrıca literatür taramasında, sonuçların değerlendirilmesi için daha çok performans ölçütü olarak MAPE ve MSE değerlerinin dikkate alındığı tespit edilmiştir.

Ayrıca teknolojinin gelişmesiyle birlikte halı üretim makinelerinde de gelişmeler olmuş ve bu alandaki çalışmalar artmıştır. Geleneksel cağlık sadece basit çerçeve ve demir direk içerir, bobinler direk üzerindedir ve dokuma tezgâhına iplik sağlar. Tezgâh halı dokurken, işçiler hangi bobinin bitmek üzere olduğunu kontrol etmeli ve değiştirmelidir. Geliştirilen akıllı cağlık sistemi ile son yapılan çalışmalar halı üretiminde zaman ve malzeme israfının önüne geçilebileceğini göstermektedir.

İncelenen çalışmalar doğrultusunda YSA yönteminin klasik istatistiksel yöntemlere göre çok daha başarılı olduğu ve hibritleştirilmiş sinir ağlarının da diğer YSA ağların tek tek uygulanmasına göre daha iyi sonuçlar verdiği görülmüştür.

3. MATERYAL VE METOT

3.1. Materyal

Bu çalışmada, halı üretimi sürecinde yer alan dokuma bölümünde önem arz eden çağ değişim süreçlerinin çeşitli modeller geliştirilerek tahminlemesi yapılmıştır. 2017-2018 yılları arasında 9 aylık süreci kapsayan veri seti Gaziantep'te bulunan bir halı firmasından alınmıştır.

Bu firma, yerli ve yabancı halı pazarının önde gelen firmalarından biridir ve Türkiye'nin en büyük 500 sanayi kuruluşu (ISO500) arasında ilk 500'de yer almaktadır. Gaziantep Organize Sanayi Bölgesinde 50.000 m² kapalı alanda faaliyet göstermektedir. Markalı ürünleriyle hem Türkiye'de hem de yurt dışında geniş bir müşteri yelpazesine sahiptir. Firmada üç ana süreç bulunmaktadır:

1. BCF iplik üretimi
2. Dokuma
3. Konfeksiyon

3.1.1. Dokuma


Bu firmada 38 dokuma makinesi bulunmaktadır. Bu makineler Van de Wiele markası olup tarak numarasına göre farklılık göstermektedir. 16, 32, 42, 48,50 ve 100 olmak üzere 6 farklı tarak numarası bulunmaktadır. Dokuma bölümünün yıllık üretim kapasitesi alan halısı olarak yaklaşık 10 milyon m²'dir. Bir halının sıklığı (yoğunluğu), atkı ve tarak numarası arttıkça artar. Her makinenin üretim kapasitesi o sırada üretilen halının modeline göre değişmektedir. Örneğin; 16 tarak numaralı makine daha hızlı ve büyük miktarda halı üretir. Ancak 100 tarak numaralı makinenin üretimi daha yavaştır. Çalışmada kullanılan veri seti için tarak numarası, renk ve tezgâh enine göre farklılık gösteren özet veri seti Çizelge 3.1.'de gösterilmiştir. Çizelge 3.1' de de görüldüğü üzere 6 farklı dokuma tarak numarası, 4

farklı renk ve 4 farklı tezgâh enine bağlı olarak dokuma tezgâhının çağ (bobin) kapasitesi değişmektedir.

Çizelge 3.1. Özet veri seti

Tarak Numarası	Renk	Tezgâh Eni (m)	Tezgâh Bobin Kapasitesi	Tezgâhta Değişen Bobin Sayısı	Duruş Süreleri (dk.)
16	6	4	3.840	33600	7760
16	6	5	4.800	51440	9015
16	8	5	6.400	14532	5410
16	8	4	5.120	24224	3130
32	8	4	10.240	31680	35040
32	8	2,5	6.400	6642	13935
42	8	4	13.440	14410	5575
42	10	5	21.000	9966	5385
48	10	4	19.200	14457	8190
48	6	5	14.400	8000	10445
50	16	4	32.000	7133	10345
100	8	3	24.000	8400	4030
100	8	4	32.000	27830	24210

Şekil 3.1, firmanın dokuma birimi iş akış şemasını göstermektedir. Şekil 3.1’de de görüldüğü üzere çağ değişim süreci dokuma biriminde yer almakta olup bu sürecin öngörülerek bu doğrultuda planlama yapılması ya da sürenin azaltılmasına yönelik çalışmalar yapılması firma için önemlidir. Çünkü çağ değişimi yapılan tezgâhta üretim durmaktadır.



Şekil 3.1. Dokuma birimi iş akış şeması

3.1.2. Verilerin Düzenlenmesi

Dokuma bölümünde tezgâh duruşları, kullanılan sistem kayıtlarına göre planlama, elektronik, dokuma kaynaklı duruşlar ve diğer duruşlar olmak üzere 4 ana grupta toplanmaktadır. Çizelge 3.2.' de tezgâh duruşlarının bu 4 ana gruba göre sınıflandırılması yapılmıştır.

Çizelge 3.2. Duruşların sınıflandırılması

Planlama Kaynaklı Duruş	Elektronik Kaynaklı Duruş	Dokuma Kaynaklı Duruş	Diğer Duruşlar
Cağ Değişimi	Elektrik Arıza	Revizyon	Toplantı
Renk Çekimi Zemin Çekimi Misina Çekimi	Klavye Arızası	Mekanik Arıza Mekanik Ayar	Cuma Namazı Tatiller
Cağ Ayarlaması	Motor Arızası	Şark-Harniş Değişimi	Temizlik
Bölme Beklendi	Kart Değişimi	Hav Teli Çekimi	Jüt Bozuk
Renk Bandı Apreye Gönderildi	Solenoid Değişimi	Yay Değişimi	Elektrik Kesintisi
Palet Hatası	Atkı Motoru Arızası	Kenar Saçak Patlaması	Yağ Isınması
Hav Yükseklik Ayarı	Hava Basıncı	Makas Arızası	Kalite Kontrol Duruşu
Lanset Değişimi		Tezgâh Ayarlama	Abraj
Bağlantı-Dolgu Çözgü Değişimi		Platin Değişimi Mekik, Rapiier Değişimi	Program Bekledi Forklift Beklendi Halı Arabası Beklendi

Bu çalışmanın konusunu ilgilendiren çağ değişim sürelerini kapsayan kaynaklar sistemde planlama kaynaklı duruşlar başlığı altında toplanmaktadır. Veri seti, 2017-2018 yılları arasında çağ değişimini doğrudan ilgilendiren planlama kaynaklı duruşlardan oluşan 308 veriden oluşmaktadır.

Tarak numarası, tezgâh eni, renk, tezgâh bobin kapasitesi ve tezgâhta değişen bobin sayısı girdi değişkeni olarak belirlenmişlerdir. Tezgâhta değişen bobin sayısı tezgâh duruşlarına sebep olan renk çekimi, çağ değişimi gibi bobin değişimi gerektirecek işlemleri kapsamaktadır.

3.2. Metot

Bu çalışmada, çağ değişim sürelerinin tahmini için bağımlı ve bağımsız değişkenler arasında herhangi bir ön bilgiye sahip olmadan diğer tahmin yöntemlerine göre daha avantajlı ve başarılı sonuçlar üretebilen YSA modelleri kullanılmıştır.

Tahminleme problemi için yapay sinir ağı yöntemlerinden MLP ve GRNN modelleri ile birlikte regresyon analizi kullanılmıştır. Bu problemin çözümü için elde edilen sonuçlar karşılaştırılarak elde edilen en iyi sonuçlarla oluşturulan yeni bir hibrit sistem tercih edilmiştir.

Bu amaçla oluşturulan ağların eğitimi ve test edilmesi için kod yazılımı yapılmıştır.

YSA yapısını oluşturan gizli katmandaki nöron sayısı, aktivasyon fonksiyonu ve eğitim algoritması parametreleri ortaya çıkan ağın performansını etkiler. Bu nedenle farklı ağ topolojilerine ve öğrenme parametrelerine sahip modeller oluşturulmuş ve deneyler yapılmış ve elde edilen sonuçlar her bir ağın MAPE değerleri kullanılarak karşılaştırılmıştır. Probleme en uygun ağ deneme yanılma yoluyla bulunmuştur.

Bu çalışma için tasarlanan YSA modeli Ek 1’de detaylı olarak gösterilmiştir.

3.2.1. Yapay Sinir Ağı Modellerinin Seçimi

YSA modeli için bu çalışmada, bir halı firmasının 2017-2018 yılları arasındaki dokuma bölümü çağ değişim verileri kullanılmıştır. Çağ değişim verileri, günlük olarak tutulan dokuma raporlarında yer alan parametre değerlerinden tarak numarası, tezgâh eni, renk, tezgâh bobin kapasitesi, tezgâhta değişen bobin sayısı verileri ve tezgâhların çağ değişim boyunca duruş süreleri makine üzerinde bulunan sistemden rapor şeklinde alınmıştır. Çalışmada normalizasyon uygulanmış veri seti kullanılmıştır. Literatürde eğitim ve test setlerinin büyüklüklerinin belirlenmesi konusunda fikir birliği yoktur. Çoğu araştırmacı, eğitim ve test setlerini %90'a karşı %10 veya %80'e karşı %20 veya %70'e karşı %30 kuralıyla seçer (Zhang ve ark., 1998).

YSA modeli; beş girdi değişkeni ve bir çıktı değişkeni ile oluşturulmuş olup, literatürde eğitim ve test setlerinin büyüklüklerinin belirlenmesi konusunda fikir birliği olmadığından, YSA modelinde eğitim, doğrulama ve test verileri modellerde %70-%15-%15 ve %70-%10-%20 olmak üzere iki şekilde rassal olarak ayrıştırılmıştır. Veri setlerinin dağılım olarak farklı oranlarda seçilmesinin sebebi tahmin başarısındaki etkisini görebilmek ve daha uygun model elde edebilmek adına.

3.2.1.1. Verilerin Normalizasyonu

Kullanılan veri türleri (adet, dk., m) farklı olduğu ve aralarında yüksek değerlerin bulunduğu değişkenler olduğu için daha sağlıklı sonuçlar elde edebilmek adına programda kullanılmadan önce veriler normalize edilmiştir. Ayrıca verilerin normalleşmesi, YSA yönteminin doğrusal olmayan problemlerin çözümünde kullanılmasını çok daha anlamlı kılmaktadır. Çünkü verilerin birbirine üstünlüğü olmadığı halde, veri türlerinin farklı olması ve veriler arasındaki farkın çok olması durumunda program verileri birbirine karşı üstün olarak algılayabilir.

Bu çalışmada verileri normalleştirmek için basit normalizasyon yöntemi kullanılmıştır. Basit normalizasyon yönteminde max verilerdeki en yüksek değeri

temsil eder ve bu yöntemle, veriler [0,1] aralığına indirgenir. Normalleştirme için kullanılan formül denklem (3.1) 'de gösterilmiştir:

$$x = \frac{x_0}{x_{max}} \quad (3.1)$$


3.2.1.2. Yapay Sinir Ağının Yapısı

Çalışmada, MLP, GRNN ve regresyon analizi kullanılmış olup en iyi tahmin değerini veren YSA modeli belirlenmiş ve bu en iyi sonuçları veren modelleri birleştiren yeni bir hibrit modeli oluşturulmuştur. Dört yöntem ile elde edilen sonuçlar karşılaştırılarak performans ölçütlerine göre değerlendirilmesi yapılmıştır. Bu uygulamalar aşağıda ayrıntılı olarak açıklanmıştır.

3.2.2. MLP Ağı

3.2.2.1. MLP Ağı Parametre Optimizasyonu

Yapay sinir ağı yapısı; girdi katmanı, gizli katman, çıktı katmanı ve her katmanda bulunan gizli nöron sayısından oluşmaktadır. Ağı yapısı; girdi katmanı, gizli katmanlar ve çıktı katmanı olmak üzere çok katmanlı olacak şekilde tasarlanmıştır. Şekil 3.2' de MLP ağ yapısı gösterilmektedir.



Şekil 3.2. Çalışmada kullanılan MLP ağ yapısı

Gizli katmanda bulunan nöron sayısı, birinci bölümde bahsedilen formül kullanılarak hesaplanmıştır. Hesaplama sonucu nöron sayısı;

$$N_s = \frac{\frac{1}{2}(5 + 1) + \sqrt{308}}{3} = 6,85 \sim 7 \text{ olarak bulunmuştur.}$$

Gizli katman için nöron sayısı 7 olarak hesaplanmış fakat daha iyi sonuçlar elde edebilmek adına farklı nöron sayılarıyla da denemeler yapılmıştır.

Yapay sinir ağlarında en iyi yapıya ulaşmak için hiper parametre optimizasyonu kullanılmıştır. Çalışmada kullanılan YSA parametreleri Çizelge 3.3’te verilmiştir. Denemeler sonucunda, her bir model için en iyi tahmin modeli belirlenmiştir. Bu modeller belirlenen performans ölçütüne göre kıyaslanmıştır.

Çizelge 3.3. Çalışmada kullanılan YSA parametreleri

Veri Bölme Yüzdeleri	"%70-%15- %15" "%70- %10- %20"
Gizli Katman Sayısı	1- 2-3
Nöron Sayısı	5- 7- 8- 10- 11- 12- 13- 14- 15- 20
Öğrenme Oranı	0,01- 0,1- 0,3- 0,5- 0,9
Momentum Oranı	0,1- 0,5- 0,9
İterasyon Sayısı	300- 500- 750- 1000
Eğitim Fonksiyonu	Levenberg-Marquardt BFGS Quasi-Newton Esnek Geri Yayılma Ölçekli Eşlenik Gradyan Powell-Beale Eşlenik Gradyan
Aktivasyon Fonksiyonu	Doğrusal Aktivasyon Fonksiyonu Logaritmik Sigmoid Aktivasyon Fonksiyonu Doymuş Doğrusal Aktivasyon Fonksiyonu Pozitif Doğrusal Aktivasyon Fonksiyonu Hiperbolik Tanjant Sigmoid Aktivasyon Fonksiyonu

3.2.2.2. Performans Ölçütü ile Kıyaslama

YSA modelleri ile tahmin edilen çağ değişim sürelerinde test verilerini karşılaştırmak için birinci bölümde bahsedilen performans ölçütlerinden MAPE kullanılmıştır.

Birinci bölümde bahsedilen MSE, RMSE, MAE gibi ölçütler arasında değerlendirmede tek başına bir anlam ifade etmesi nedeniyle MAPE ölçütünün tahmin hatalarını yüzde olarak belirtmesi diğer performans ölçütlerine göre daha üstün kabul edilmiştir (Witt ve Witt, 1995). Ayrıca Lewis (1982)'e göre, MAPE değerleri %10'un altında olan modeller "çok iyi", %10 ile %20 arasında olan

modeller “iyi”, %20 ile %50 arasında olan modeller “kabul edilebilir” seviyede ve %50’nin üzerinde olan modeller ise “yanlış ve hatalı” olarak kabul edilmektedir (Yakut, Elmas ve Yavuz, 2014).

MAPE değerlerine göre elde edilen sonuçlar karşılaştırılarak en iyi modele karar verilmiştir.

3.2.3. GRNN Ağı

YSA modellerinden GRNN yöntemi de kullanılarak çağ değişim süreleri tahminlenmiştir. MLP ağında belirlenen parametrelere göre elde edilen sonuçlar MAPE ölçütüne göre karşılaştırılarak en iyi model belirlenmiştir. GRNN ağıının uygulanmasında, en iyi MLP modelinin eğitim, doğrulama ve test veri seti dağılım oranı, eğitim ve aktivasyon fonskiyonu parametreleri aynı alınarak GRNN ağı uygulanmıştır.

GRNN ağı radyal değer 0,01 ile 1 arasındaki tüm değerler için uygulanarak toplam 100 deneme yapılmıştır. Bu deneme sonuçları MAPE ölçütüne göre karşılaştırılarak en iyi GRNN ağı bulunmuştur.

3.2.4. Çoklu Regresyon Analizi


Çoklu regresyon analizi istatistiksel uygulama kullanılarak yapılmıştır. Regresyon analizinde MLP ağında bulunan en iyi modelin eğitim veri seti kullanılarak tespit edilen değişken katsayıları tüm veri setine uygulanmış ve çıktı değerleri elde edilmiştir.

3.2.5. Hibrit Model

Literatür çalışmasında da görüldüğü üzere son zamanlarda yapılan çalışmalarda hibrit sinir ağları sıkça kullanılmaktadır. Hibrit ağların performansının genelde sistemi oluşturan diğer ağların tek tek performanslarından daha yüksek olduğu görülmektedir.

Bu çalışmada da ayrı ayrı kullanılan MLP, GRNN ve çoklu regresyon analizi modelleri oluşturulduktan sonra daha iyi sonuçlar elde edebilmek için bu üç modeli birleştiren hibritleştirme yaklaşımı denenmiştir.

Çalışmada kullanılan hibrit sisteme göre MLP ve GRNN ağlarından elde edilen en iyi modellerin tahminleri ile çoklu regresyon analizi tahmini birleştirilerek tekrar MLP ağına sunulmuştur (Şekil 3.3). Hibrit model için kullanılan yeni MLP ağında; daha önce kullanılan MLP, GRNN ve çoklu regresyon analizinin çağ değişim sürelerinin tahmin değerleri üç girdi ve gerçekleşen çağ değişim süreleri ise çıktı olacak şekilde tasarlanmıştır. Hibrit model için de belirlenen parametreler ile denemeler yapılarak MAPE performans ölçütüne göre en iyi ağ modeli seçilmiştir.



Şekil 3.3. Çalışmada kullanılan hibrit sinir ağ yapısı



4. BULGULAR


Çalışmanın bu bölümünde MLP, GRNN, çoklu regresyon analizi ve hibrit sistem yöntemleri kullanılarak elde edilen sonuçlar ayrı ayrı ele alınarak en iyi yöneme karar verilmiştir.

4.1. Veri Analizi

Çalışmaya konu olan çağ değişim sürelerinin tahmini için kullanılan örnek veri seti daha önce çalışmanın üçüncü bölümünde Çizelge 3.1’ de gösterilmişti. Çalışma için girdi verilerini oluşturan tarak numarası, renk, tezgâh eni, tezgâh bobin kapasitesi ve tezgâhta değişen bobin sayısı değişkenlerine ve çıktı olan çağ değişim kaynaklı duruş sürelerine ait histogram grafikleri Şekil 4.1’ de gösterilmektedir. Tüm değişkenlere ait değişkenliğin yüksek olduğu görülmektedir. Tezgâhta değişen bobin sayısı ve çağ değişimi duruş süreleri parametreleri benzer modellere sahiptir; bu nedenle tahmin için yüksek potansiyel beklenebilir.

Çalışmanın üçüncü bölümünde de belirtildiği üzere verilerin normalize edilmesi YSA yönteminin problemlerin çözümünde kullanılmasını çok daha anlamlı kılmakta ve veri türlerinin farklı olması, veriler arasındaki farkın çok olmasından kaynaklı birbirlerine üstün olarak algılanması gibi sebepleri elimine ederek daha başarılı sonuçlar elde edilebilmesini sağlamaktadır.

308 veriden oluşan veri seti için maksimum değerler; tarak numarası için 100, tezgâh eni için 5 m, renk için 16, tezgâh bobin sayısı kapasitesi için 32.000 bobin, değişen bobin sayısı için 282.365 bobin ve duruş süresi için 35040 dakikadır. Denklem 3.1. kullanılarak örnek veri setinin (Çizelge 3.1) normalize edilmiş hali Çizelge 4.1’de gösterilmiştir.



Şekil 4.1. Değişkenlere ait histogram grafikleri

Çizelge 4.1. Örnek veri setinin normalize değerleri

Tarak Numarası	Renk	Tezgâh Eni (m)	Tezgâh Bobin Kapasitesi	Tezgâhta Değişen Bobin Sayısı	Duruş Süreleri (dk.)
0,16	0,375	0,8	0,12	0,118995	0,221461
0,16	0,375	1	0,15	0,182176	0,257277
0,16	0,5	1	0,2	0,051465	0,154395
0,16	0,5	0,8	0,16	0,08579	0,089326
0,32	0,5	0,8	0,32	0,112195	1
0,32	0,5	0,5	0,2	0,023523	0,397688
0,42	0,5	0,8	0,42	0,051033	0,159104
0,42	0,625	1	0,65625	0,035295	0,153682
0,48	0,625	0,8	0,6	0,0512	0,233733
0,48	0,375	1	0,45	0,028332	0,298088
0,5	1	0,8	1	0,025262	0,295234
1	0,5	0,6	0,75	0,029749	0,115011
1	0,5	0,8	1	0,09856	0,690925

Bağımsız ve bağımlı değişkenler arasındaki doğrusal ilişkiyi kontrol etmek için korelasyon matrisi kullanılmaktadır. Çizelge 4.2, çağ değişimi değişkenleri için korelasyon matrisini göstermektedir. Çizelge 4.2 incelendiğinde çağ değişimi duruş süreleriyle en fazla ilişkinin histogramlardan yorumlandığı şekliyle tezgâhta değişen bobin sayısı ile olduğu görülmekte olup en güçlü ilişkinin çağ kapasitesi ile tarak numarası değişkenleri arasında olduğu tespit edilmiştir. Ayrıca p değerleri incelendiğinde p değeri 0,05' ten küçük olan iki değişken arasında anlamlı bir ilişkinin olduğu söylenebilir.

Çizelge 4.2. Çağ değişimi değişkenleri için korelasyon matrisi

		Duruş Süreleri	Tarak Numarası	Renk	Tezgâh Eni	Tezgâh Bobin Kapasitesi
Tarak Numarası	Korelasyon Katsayısı	0,153				
	p Değeri	0,286				
Renk	Korelasyon Katsayısı	0,154	0,232			
	p Değeri	0,86	0,000			
Tezgâh Eni	Korelasyon Katsayısı	-0,037	-0,235	-0,103		
	p Değeri	0,709	0,000	0,071		
Tezgâh Bobin Kapasitesi	Korelasyon Katsayısı	0,195	0,837	0,625	0,056	
	p Değeri	0,464	0,000	0,000	0,326	
Tezgâhta Değişen Bobin Sayısı	Korelasyon Katsayısı	0,304	-0,203	-0,067	-0,041	-0,223
	p Değeri	0,000	0,000	0,238	0,476	0,000

4.2. MLP Sonuçları


Cağ değişim sürelerinin tahmini için çalışmada kullanılan ilk yapay sinir ağı modeli MLP ağıdır. 5 girdi ve 1 çıktı olmak üzere 308 veri setinden oluşan ağ yapısı ile toplam 1050 deneme yapılmıştır. Bu denemelerden en iyi on deneme Çizelge 4.3’de verilmiştir.



Çizelge 4.3. MLP modeline ait en iyi 10 deneme

Deneme	Veri Dağılımı	Öğrenme Katsayısı	Momentum Katsayısı	Gizli Kat. Nöron Sayısı	Gizli Katman Sayısı	Eğitim Fonksiyonu	Aktivasyon Fonksiyonu	İterasyon	MAPE Eğitim	MAPE Test
305	70-15-15	0,1	0,5	10	1	Levenberg-Marquardt	Logaritmik Sigmoid	500	0,24	0,25
473	70-10-20	0,1	0,1	15	1	BFGS Quasi-Newton	Doymuş Doğrusal Aktivasyon Fonksiyonu	1000	0,36	0,26
540	70-10-20	0,1	0,1	15	2	Levenberg-Marquardt	Hiperbolik Tanjant Sigmoid	500	0,19	0,24
549	70-10-20	0,1	0,1	15	2	BFGS Quasi-Newton	Doymuş Doğrusal Aktivasyon Fonksiyonu	1000	0,20	0,25
570	70-10-20	0,1	0,1	15	2	Esnek Geri Yayılma	Hiperbolik Tanjant Sigmoid	1000	0,26	0,26
913	70-15-15	0,3	0,5	20	1	Levenberg-Marquardt	Hiperbolik Tanjant Sigmoid	300	0,49	0,26
935	70-15-15	0,3	0,5	20	1	Esnek Geri Yayılma	Logaritmik Sigmoid	500	0,35	0,26
1009	70-15-15	0,3	0,5	20	2	Esnek Geri Yayılma	Logaritmik Sigmoid	300	0,31	0,26
1010	70-15-15	0,3	0,5	20	2	Esnek Geri Yayılma	Logaritmik Sigmoid	500	0,31	0,26
1048	70-15-15	0,3	0,5	20	2	Ölçekli Eşlenik Gradyan	Hiperbolik Tanjant Sigmoid	300	0,44	0,26

Performans ölçütlerinden test verisi MAPE değerine göre yapılan değerlendirmeler doğrultusunda MLP ağı için en başarılı model 540. deneme sonucu elde edilen MLP540 ağı modeli olarak belirlenmiştir. MLP540 ağı model yapısı Şekil 4.2.'de ve modele ait ağı parametreleri Çizelge 4.3.' te belirtilmiştir.



Şekil 4.2. MLP540 modeli ağı yapısı


Şekil 4.2'de belirtilen en iyi MLP ağı modeline ait ağı yapısında girdi katmanında girdi değişkenlerinin ağı sunulmasını sağlayan 5 adet nöron, 15' er adet nörondan oluşan 2 gizli katman ve çıktı katmanında bağımlı değişkene ait ağı çıktısının alındığı 1 adet çıktı nöronu bulunmaktadır.

Çizelge 4.4. MLP540 sinir ağı parametreleri

Model	MLP540
Girdi Katmanı Nöron Sayısı	5
Gizli Katman Sayısı	2
Gizli Katmanlardaki Nöron Sayısı	15
Çıktı Katmanı Nöron Sayısı	1
Eğitim-Doğrulama-Test Dağılımı	%70-%10-%20
Eğitim Fonksiyonu	Levenberg- Marquadt Fonksiyonu
Aktivasyon Fonksiyonu	Hiperbolik Tanjant Sigmoid Fonksiyonu
İterasyon	500
Öğrenme Katsayısı	0,1
Momentum Katsayısı	0,1

Çizelge 4.4'te belirtilen eğitim-doğrulama-test verileri başlangıç aşamasında %70-%10-%20 oranı ile dağılmış olup değerlendirme aşamasında doğrulama ve test verileri birleştirilmiştir.

MLP yöntemi ile deneme yapılan modeller MAPE değerlerine göre karşılaştırılarak Çizelge 4.4' te parametreleri belirtilen MLP540 sinir ağı çıktı değerleri gerçek çıktı değerlerine en iyi yakınsayan model olmuştur.




Şekil 4.3. MLP540 MSE grafiği

Şekil 4.3'te, MSE değeri eğitim, doğrulama ve test adımları için 500 iterasyonda kararlı durum konumuna ulaşmış ve en iyi doğrulama performansı 102. iterasyona ait 0,0058 MSE değeridir.


Regresyon çizgi grafiklerini açıklamadan önce, R'nin açıklanması daha doğru olacaktır. R, "bağımsız değişken ile bağımlı değişken arasındaki ilişkinin yönü ve gücü" olarak tanımlanabilir (Krajewski ve ark., 2013). R değeri + 1'e yaklaştıkça veri noktalarının regresyon doğrusu ile uyumu artar.

Şekil 4.4, her bir veri seti için regresyon grafiklerini gösterir. Şekil 4.4 'te her daire veri noktalarını gösterir. Her veri noktası regresyon çizgisine yakınsadıkça, en küçük kare hata değeri azalır. Bunun yanı sıra regresyon grafiğine göre kullanılan hedef ile veri arasındaki uyum görülebilir.



Şekil 4.4. MLP540 modelinin her veri grubu için R grafikleri

Şekil 4.4’ te, MLP540 YSA modelinin veri setinde çağ değişim sürelerinin tahmin değerleri ile gerçek değerleri arasında bir ilişki olduğu gözlemlenmektedir. MLP540 modelinin determinasyon katsayısı (R^2) değerinin tüm çağ değişim süreleri için 0.69 olduğu tespit edilmiştir. Bu değer %69 çıkması, toplam değişimin %69’unun kurulan modelle belirlenmiş olduğu, %31’inin ise ya tesadüfen meydana gelmiş ya da dikkate alınmayan başka değişkenlerce belirlenmiş olduğu anlamına gelmektedir.



Şekil 4.5. Çağ değişim süreleri için MLP540 tahminleri ile gerçek değerler arasındaki karşılaştırma

Şekil 4.5’te çağ değişim süreleri için MLP540 model ağ tahminlerinin gerçek değer trendini izlediği gözlemlenmekle beraber tepe noktaların yani tahmin ile gerçek değer arasındaki en çok sapmanın renk için 8 ve tezgâh eni için 4 m özelliğe sahip verilerde olduğu tespit edilmiştir. Elde edilen sonuçlar tezgâh eni ve renk özelliklerine bakılarak detaylı incelendiğinde çağ değişim sürelerinin tezgâhta

değişen bobin sayısına bağlı aynı yönde ilerlemediği gözlemlenmiştir. Bu doğrultuda tezgâhta çalışan operatör ve çağ değişim ekibinin de çağ değişim sürelerinde etkili olabileceği düşünülmektedir.

Test verisi üzerindeki MAPE değeri düşük olan MLP540 ağ modeli en iyi olarak belirlenmiş ve MLP540 modeline ait sonuçlar Çizelge 4.5’ te verilmiştir.

Çizelge 4.5. MLP540 performans ölçütleri

Performans Ölçütü	Eğitim	Test	Tüm Veri Seti
MAPE	0,19	0,24	0,21
MSE	0,0041	0,0097	0,006
R	0,90	0,66	0,83

Bu çalışmada esas alınan performans ölçütlerinden MAPE değeri, MLP540 ağ modelinin test verisi için incelendiğinde 0,24 ile Lewis (1982)’ e göre kabul edilebilir model olarak ifade edilebilir.

4.3. GRNN Sonuçları


Çağ değişim sürelerinin tahmini için çalışmada kullanılan ikinci yapay sinir ağı modeli GRNN ağıdır. 5 girdi ve 1 çıktı olmak üzere 308 veri setine ait GRNN ağ modeli ile radyal değerler 0,01 ile 1 arasında değiştirilerek 100 deneme yapılmıştır. Bu denemelerden en iyi on deneme Çizelge 4.6’da verilmiştir.

Çizelge 4.6. GRNN modeline ait en iyi 10 deneme

Deneme	Radyal Değer	MAPE Eğitim	MAPE Test
1	0,01	0,252	0,309
2	0,02	0,380	0,324
3	0,03	0,466	0,350
4	0,04	0,518	0,374
5	0,05	0,556	0,393
6	0,06	0,586	0,410
7	0,07	0,610	0,426
8	0,08	0,629	0,439
9	0,09	0,646	0,450
10	0,1	0,660	0,457


GRNN ağında eğitim ve test verileri için daha önce MLP ağ modelinde en başarılı ağ olarak tespit edilen MLP540 ağında ayrıştırılmış olan eğitim ve test veri setleri kullanılmıştır. Farklı ağ modellerinin karşılaştırılmasında aynı veri setinin kullanılması daha sağlıklı olacağı için MLP540 ağına ait eğitim ve test verileri kullanılmıştır.

Performans ölçütlerinden test verisi MAPE değerine göre yapılan değerlendirmeler doğrultusunda GRNN ağı için en başarılı model 1. deneme sonucu elde edilen GRNN1 ağ modeli olarak belirlenmiştir. GRNN1 ağı model yapısı Şekil 4.6' da belirtilmiştir.



Şekil 4.6. GRNN1 ağ yapısı

Test verisi üzerindeki MAPE değeri düşük olan 0,01 radyal değerinde GRNN1 ağ modeli en iyi olarak belirlenmiştir.



Şekil 4.7. GRNN1 modelinin her veri grubu için R grafikleri

R değeri + 1'e yaklaştıkça veri noktalarının regresyon doğrusu ile uyumu artar ancak Şekil 4.7' de görüldüğü üzere GRNN1 ağ modeli için kullanılan hedef ile veri arasındaki uyum çok düşüktür.

GRNN1modeline ait sonuçlar Çizelge 4.7’ de verilmiştir.

Çizelge 4.7. GRNN1 performans ölçütleri

Performans Ölçütü	Eğitim	Test	Tüm Veri Seti
MAPE	0,25	0,30	0,75
MSE	0,020	0,017	0,019
R	0,49	0,09	0,47

GRNN1 ağ modelinin test verisi için MAPE değeri incelendiğinde bu değerlerin %20 ile %50 arasında değer aldığı görülmüş olup Lewis (1982)’e göre bu model kabul edilebilir modeller olarak ifade edilmiştir.

Ancak; MAPE değerleri göz önünde bulundurulduğunda tahmin etmede MLP540 modelinin GRNN1 modelinden daha başarılı bulunduğu belirlenmiştir.

4.4. Çoklu Regresyon Analizi Sonuçları

Çalışmanın üçüncü bölümünde bahsedildiği gibi regresyon analizi için MLP ağında bulunan en iyi model olan MLP540 ağına ait eğitim veri seti kullanılarak tespit edilen değişken katsayıları tüm veri setine uygulanmış ve çıktı değerleri elde edilmiştir.

Regresyon analizi sonucunda değişken katsayıları Çizelge 4.8’ deki gibi tespit edilmiştir.

Çizelge 4.8. Eğitim veri seti için çoklu regresyon analizi katsayıları

Değişken	B	Standart Hata	Beta	t	p
Sabit*	,513	,239		2,145	,033
Tarak Numarası	-,327	,247	-,406	-1,321	,188
Renk	-,453	,276	-,292	-1,642	,102
Tezgâh Eni	-,162	,149	-,143	-1,085	,279
Tezgâh Bobin Kapasitesi	,434	,267	,610	1,623	,106
Tezgâhta Değişen Bobin Sayısı	,687	,069	,583	10,007	,000

*Cağ değişim duruş süresi- (Bağımlı değişken) Sabit

* R= 0,571

Analiz sonucunda oluşan Regresyon denklemi aşağıda verilmiştir.

Duruş Süresi= 0,513-0,327 Tarak Numarası-0,453 Renk-0,162 Tezgâh Eni+ 0,434 Tezgâh Bobin Kapasitesi+0,687 Tezgâhta Değişen Bobin Sayısı

Bulunan tarak numarası (-0,327), renk (-0,453), tezgâh eni (-0,162), tezgâh bobin kapasitesi (0,434) ve tezgâhta değişen bobin sayısı (0,687) değişken katsayıları kullanılarak hibrit modele girdi sağlanmıştır. Regresyon analizi çıktısında birinci bölümde de bahsedilen denklem 4.1'deki formül kullanılmıştır.


$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_5 \quad (4.1)$$

y= Regresyon analizi çıktıları

x= Eğitim seti girdi değişkenleri

β_0 = Sabit sayı

β_1 = Her değişken (x=1 ,2, 3, ..., k) için regresyon katsayısı



Şekil 4.8. Çoklu regresyon analizinin veri seti için R grafiği

Eğitim veri seti için belirlenen katsayıların kod yazılımı tüm veri setine uygulanması sonucu elde edilen Şekil 4.8’de incelendiğinde regresyon analizi için kullanılan hedef ile veri arasındaki uyumun düşük olduğu tespit edilebilmektedir.

Çizelge 4.9. Çoklu regresyon analizi performans ölçütleri

Performans Ölçütü	Eğitim	Test	Tüm Veri Seti
MAPE	0,34	0,33	0,60
MSE	0,014	0,013	0,014
R	0,57	0,49	0,54

Çizelge 4.9’da çoklu regresyon modelinin test verisi için MAPE değeri incelendiğinde bu değerlerin %20 ile %50 arasında değer aldığı görülmüş olup Lewis (1982)’e göre bu model kabul edilebilir modeller olarak ifade edilmiştir.

4.5. Hibrit Model Sonuçları


MLP, GRNN ve çoklu regresyon ile oluşturulan çağ değişim süreleri tahmin modelleri arasından test verisi üzerinde sırasıyla 0,25, 0,30 ve 0,33 MAPE değerleri ile en iyi sonucu veren MLP540, GRNN1 ve regresyon modellerinin elde edilmesinden sonra, daha iyi bir sonuç elde edebilmek için hibrit sinir ağı kullanılmıştır. Bunun için, hibrit yapay sinir ağı için MLP modelinin kullanılması tercih edilmiştir.

Hibrit sistem MLP540, GRNN1 ve regresyon modelleri sonucu elde edilen tahmin değerleri girdi, gerçek çağ değişim süreleri ise çıktı olacak şekilde tasarlanmıştır. 3 girdi ve 1 çıktı olmak üzere 308 veri setinden oluşan hibrit ağ yapısı için de parametre optimizasyonu yapabilmek için 6000 deneme yapılmıştır. Bu denemelerden en iyi on deneme Çizelge 4.10’da verilmiştir.

Çizelge 4.10. Hibrit modeline ait en iyi 10 deneme

Deneme	Veri Dağılımı	Öğrenme Katsayısı	Momentum Katsayısı	Gizli Kat. Nöron Sayısı	Gizli Katman Sayısı	Eğitim Fonksiyonu	Aktivasyon Fonksiyonu	İterasyon	MAPE Eğitim	MAPE Test
7	70-15-15	0,3	0,5	10	1	BFGS Quasi-Newton	Logaritmik Sigmoid	300	0,22	0,18
1272	70-15-15	0,1	0,5	13	1	Levenberg-Marquardt	Doğrusal Aktivasyon Fonksiyonu	300	0,23	0,19
1273	70-15-15	0,1	0,5	13	1	Levenberg-Marquardt	Doğrusal Aktivasyon Fonksiyonu	500	0,24	0,20
1334	70-15-15	0,1	0,5	13	1	Ölçekli Eşlenik Gradyan	Doğrusal Aktivasyon Fonksiyonu	1000	0,24	0,19
1355	70-15-15	0,1	0,5	13	2	Levenberg-Marquardt	Doymuş Doğrusal Aktivasyon Fonksiyonu	1000	0,23	0,21
1377	70-15-15	0,1	0,5	13	2	Esnek Geri Yayılma	Doğrusal Aktivasyon Fonksiyonu	300	0,24	0,19
1379	70-15-15	0,1	0,5	13	2	Esnek Geri Yayılma	Doğrusal Aktivasyon Fonksiyonu	1000	0,23	0,20
1416	70-15-15	0,1	0,5	13	2	Ölçekli Eşlenik Gradyan	Pozitif Doğrusal Aktivasyon Fonksiyonu	300	0,24	0,19
5441	70-10-20	0,01	0,1	8	2	Levenberg-Marquardt	Doymuş Doğrusal Aktivasyon Fonksiyonu	1000	0,22	0,21
5443	70-10-20	0,01	0,1	8	2	Levenberg-Marquardt	Pozitif Doğrusal Aktivasyon Fonksiyonu	1000	0,21	0,19

Performans ölçütlerinden test verisi MAPE değerine göre yapılan değerlendirmeler doğrultusunda hibrit yapay sinir ağı için en başarılı model 7. deneme sonucu elde edilen HİBMLP7 ağı modeli olarak belirlenmiştir. HİBMLP7 ağı model yapısı Şekil 4.9’da ve modele ait ağı parametreleri Çizelge 4.11’ de belirtilmiştir.




Şekil 4.9. HİBMLP7 modeli ağı yapısı

Çizelge 4.11. HİBMLP7 sinir ağı parametreleri

Model	HİBMLP7
Girdi Katmanı Nöron Sayısı	3
Gizli Katman Sayısı	1
Gizli Katmanlardaki Nöron Sayısı	10
Çıktı Katmanı Nöron Sayısı	1
Eğitim-Doğrulama-Test Dağılımı	%70-%15-%15
Eğitim Fonksiyonu	BFGS Quasi-Newton
Aktivasyon Fonksiyonu	Logaritmik Sigmoid
İterasyon	300
Öğrenme Katsayısı	0,3
Momentum Katsayısı	0,5


Çizelge 4.11’ de belirtilen eğitim-doğrulama-test verileri başlangıç aşamasında %70-%15-%15 oranı ile dağılmış olup değerlendirme aşamasında doğrulama ve test verileri birleştirilmiştir.

MLP yöntemi ile deneme yapılan modeller MAPE değerlerine göre karşılaştırılarak Çizelge 4.11’ de parametreleri belirtilen HİBMLP7 sinir ağı çıktı değerleri gerçek çıktı değerlerine en iyi yakınsayan model olmuştur.



Şekil 4.10. HİBMLP7 MSE grafiği


Şekil 4.10’da MSE değeri eğitim, doğrulama ve test adımları için 300 iterasyonda kararlı durum konumuna ulaşmış ve en iyi doğrulama performansı 297. İterasyona ait 0,0053 MSE değeridir.



Şekil 4.11. HİBMLP7 modelinin her veri grubu için R grafikleri

Şekil 4.11’ de, HİBMLP7 YSA modelinin veri setinde çağ değişim süreleri tahmin değerleri ile ölçülen gerçek değerleri arasında bir ilişki olduğu gözlemlenmektedir. HİBMLP7 modelinin determinasyon katsayısı (R^2) değerinin tüm çağ değişim süreleri için 0.76 olduğu tespit edilmiştir. Bu değer %76 çıkması, toplam değişimin %76’sının kurulan modelle belirlenmiş olduğu, %24’ünün ise ya

tesadüfen meydana gelmiş ya da dikkate alınmayan başka değişkenlerce belirlenmiş olduğu anlamına gelmektedir.



Şekil 4.12. Çağ değişim süreleri için HİBMLP7 tahminleri ile gerçek değerler arasındaki karşılaştırma

Şekil 4.12’de çağ değişim süreleri için HİBMLP7 model ağ tahminlerinin gerçek değer trendini izlediği gözlemlenmekle beraber tepe noktaların yani tahmin ile gerçek değer arasındaki en çok sapmanın renk için 8 ve tezgâh eni için 4 m özelliğe sahip verilerde olduğu tespit edilmiştir. Elde edilen sonuçlar tezgâh eni ve renk özelliklerine bakılarak detaylı incelendiğinde çağ değişim sürelerinin tezgâhta değişen bobin sayısına bağlı aynı yönde ilerlemediği gözlemlenmiştir. Bu doğrultuda tezgâhta çalışan operatör ve çağ değişim ekibinin de çağ değişim sürelerinde etkili olabileceği düşünülmektedir.

Test verisi üzerindeki MAPE değeri düşük olan HİBMLP7 ağ modeli en iyi olarak belirlenmiş ve HİBMLP7 modeline ait sonuçlar Çizelge 4.12’ de verilmiştir.

Çizelge 4.12. HİBMLP7 performans ölçütleri

Performans Ölçütü	Eğitim	Test	Tüm Veri Seti
MAPE	0,22	0,18	0,20
MSE	0,0047	0,0049	0,0048
R	0,87	0,86	0,87

Bu çalışmada esas alınan performans ölçütlerinden MAPE değeri, HİBMLP7 ağ modelinin test verisi için incelendiğinde 0,18 ile Lewis (1982)' e göre iyi model olarak ifade edilebilir.


4.6. Sonuçların Karşılaştırılması

Çizelge 4.13' te MLP ve GRNN sinir ağ yöntemleriyle yapılan denemeler sonucu elde edilen en iyi ağ modelleri MLP540 ve GRNN1 ile çoklu regresyon ve son olarak hibritleştirme yöntemiyle elde edilen en iyi ağ modeli HİBMLP7 modellerine ait test MAPE değerleri gösterilmiştir.

Çizelge 4.13. En iyi modellerin karşılaştırılması

Ağ Modelleri	MAPE	MSE	R
MLP540	0,24	0,0097	0,66
GRNN1	0,30	0,017	0,09
Çoklu Regresyon	0,33	0,013	0,49
HİBMLP7	0,18	0,0049	0,86

Çizelge 4.13'te görüldüğü üzere test verisi için MAPE oranı %18 ile en düşük olan modelin HİBMLP7 ağı, en yüksek MAPE oranının ise çoklu regresyon modeli olduğu görülmektedir. Ayrıca modellere ait çağ değişim süreleri tahmin değerleri ile ölçülen gerçek değerleri arasında bir ilişkiyi gösteren R grafikleri de incelendiğinde HİBMLP7 ağ modeli R değerinin %86 ile en yüksek olduğu tespit edilmiştir. Buradan en başarılı yöntemin hibrit yapay sinir ağlarına ait olduğu görülmektedir.



Şekil 4.13. Çağ değişim süreleri için çalışmada kullanılan model tahminleri ile gerçek değerler arasındaki karşılaştırma

Dört farklı yöntem ile elde edilen en iyi çağ değişim süreleri tahmin değerleri ile gerçek değerlerin karşılaştırılması Şekil 4.13'te gösterilmiştir. Grafikte X eksenini veri seti örneklerini, Y eksenini ise çağ değişim sürelerini göstermektedir. Çizgi grafiği gerçek çıktı değerlerine en yakın trendi takip eden modelin hibrit sisteme ait olduğunu ve gerçek değerlere en az yakınsayan modelin GRNN olduğunu göstermektedir. Tek başına GRNN modelinin çağ değişim sürelerini tahmin etmede uygun olmadığı açıkça gözlemlenmektedir. Hibrit sistemden sonra diğer yöntemlere göre başarılı olan model MLP modelidir. MLP modelinin örnek 133'te büyük bir hata payına sahip olduğu görülmektedir. Bu değer detaylı incelendiğinde duruş süresinde aykırılık tespit edilmektedir. Bunun da çağ değişim esnasında tezgâhta çalışan operatöre ve çağ değişim ekibine bağlı olarak kaynaklandığı düşünülmektedir. Şekil 4.13 çoklu regresyon yöntemi tahmin sonuçlarının çok büyük aykırı değerlere sahip olduğunu ve nadiren gerçek değerlere uyduğunu göstermektedir.

Çizelge 4.14' te çalışma sonucunda en başarılı tahminleme yöntemi olarak bulunmuş hibritleştirilmiş sinir ağı modeline bağlı gerçek çıktı ve tahmin değerine göre karşılaştırıldığında tahmin edilen en iyi 5 ve en kötü 5 veri örneği sunulmuştur. Bu veri setlerine, gerçek çağ değişim süreleri ile hibritleştirilmiş sinir ağı tahmin sonuçları arasındaki MAPE değerleri incelenerek karar verilmiştir. Karar destek sistemi olarak sunulmuş YSA modellerine ait tahmin değerleri detaylı incelendiğinde hibritleştirilmiş sinir ağının gerçek çıktılarına en yakınsayan tahminlerde bulunduğu gözlemlenmektedir. Ayrıca aynı tarak numarası, renk, tezgâh eni ve tezgâh bobin kapasitesi değerlerine sahip fakat farklı değişen bobin sayısı değerine sahip girdi setine ait gerçek çağ değişim süreleri ve tahmin değerleri incelendiğinde sapmaların olduğu tespit edilmiştir. Buna göre çağ değişim sürelerine bağlı duruş sürelerinin tahmininde belirlenen girdi değişkenlerinden farklı girdi değişkenlerinin de etkili olduğu sonucuna varılmaktadır.

Sonuç olarak literatür araştırmasında da gözlemlendiği gibi bu çalışmada da klasik istatistiksel yöntemlerin YSA' ya göre daha az başarılı olduğu bir kez daha tespit edilmiştir.

Çizelge 4.14. Gerçek çıktı ve tahmin değerlerin karşılaştırılması

Tarak Numarası	Renk	Tezgâh Eni (m)	Tezgâh Bobin Sayısı	Tezgâhta Değişen Bobin Sayısı	Gerçek Duruş Süreleri (dk.)	MLP Tahmini	GRNN Tahmini	Çoklu Regresyon Tahmini	Hibrit Model Tahmini
48	6	5	14400	8000	15184	14994	9452	8398	15184
32	8	4	10240	28378	6507	6432	9491	9140	6508
42	8	4	13440	70232	35040	34403	9547	13084	35040
32	8	5	12800	47100	9327	14798	9661	17660	9323
32	8	5	12800	66738	3371	3349	9475	6170	3369
48	8	4	15360	12268	14967	7796	9448	8368	7997
42	8	4	13440	28753	16919	9504	9468	10258	9649
48	8	5	19200	7068	13415	7447	9439	8615	7693
42	8	4	13440	17729	15568	8859	9505	9501	8753
32	8	5	12800	11646	9244	4941	9464	7796	5148

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Rekabetçiliğin giderek arttığı günümüz koşullarında üretim ve hizmet sektörlerinde faaliyet gösteren firmaların müşterilerinin taleplerini zamanında ve eksiksiz karşılaması gerekmektedir. Bu durumda firmalar tarafından en doğru hammadde tüketim, üretim ve satış tahminleri yapılmalıdır.

Tahmin çalışmaları için çeşitli yöntemler kullanılmaktadır. Her yöntemin avantajları ve kullanım alanları farklıdır. Doğrusal problemler için klasik istatistiksel yöntemler yeterli olmakla birlikte, çoğu iş problemi doğrusal değildir ve klasik yöntemler yetersizdir.

Yapay zekâ ve bu disiplinin uygulamaları günümüz dünyasında artan popülaritesine ve uygulama alanlarına sahiptir. Yapay zekânın alt dallarından biri olan yapay sinir ağları, talep tahmininden bankacılık sektörüne, sağlık alanı uygulamalarından kamu sektörüne kadar pek çok alanda kullanılmakta olup elde edilen sonuçlar tatmin edici durumdadır.

Bu çalışmada halı üretimi dokuma prosesinde yer alan çağ değişim süreleri tahmin edilmektedir. Bu amaçla 308 veri kullanılmıştır. 5 girdi ve 1 çıktıdan oluşan çeşitli YSA modelleri oluşturulmuştur. Bu kapsamda MLP ve GRNN ağlarına ek olarak klasik istatistik yöntem olan çoklu regresyon analizi de kullanılmıştır. Üç modelden elde edilen performans değerlerini daha da iyileştirmek amacıyla hibritleştirme yöntemine başvurulmuştur. Bu amaçla MLP, GRNN ve çoklu regresyon analizi ile elde edilen tahmin değerleri sistemde girdi ve gerçek çağ değişim süreleri de çıktı olacak şekilde 3 girdi, 1 çıktıdan oluşan model için tekrar MLP yöntemi kullanılmıştır. Oluşturulan sinir ağ modelleri için farklı sayıda nöron ve gizli katman, farklı oranlarda eğitim, doğrulama ve test dağılımı, farklı öğrenme ve momentum katsayıları, radyal değerler ile denemeler yapılmıştır. Test verisi için performans değerleri gözlemlenerek ve en iyi sonuca ulaşılmaya çalışılmıştır.

Çalışmada Performans ölçütü olarak MAPE dikkate alınmakla beraber MSE ve R değerleri de kaydedilmiş olup önceki bölümde yer alan Çizelge 4.13'te belirtilmişti. Çizelge incelendiğinde MAPE değerinin en düşük hibrit sistemle elde edilen HİBMLP7 modeline ait olduğu görülmektedir. Ayrıca yine MSE değerinde en düşük ve R değeri en yüksek modelin HİBMLP olduğu gözlemlenmektedir. En yüksek MAPE değeri ise klasik istatistik yöntemi çoklu regresyon analizine aittir ve GRNN yöntemine ait R değeri incelendiğinde gerçek ile tahmin değeri arasındaki uyumun çok az olduğu sonucu çıkarılabilmektedir.

Bu, hibritleştirilmiş sinir ağı yönteminin çıktılarının gerçek değerlere daha yakın olduğu anlamına gelir.

Sonuç olarak hibritleştirilmiş YSA yönteminin sonuçlarının diğer yöntemler ile karşılaştırıldığında gerçek değerlere çok daha yakın olduğu ve bu nedenle hibritleştirilmiş YSA'nın daha başarılı görüldüğü sonucuna varılmıştır.

Bu çalışmada hibrit sinir ağı yönteminin çağ değişim sürelerini tahmin etmede güvenilir bir yöntem olduğu gösterilmiştir.

Bu çalışma sonucunda elde edilen değerler ile iyi bir çağ değişim planlaması yapılabilir. Çağ değişim süreleri tahmin edilerek bu değişimin olacağı tezgâh önceden izlemeye alınıp olası gecikmeler engellenebilir. Bu gecikmelerin engellenmesi firmalara çok fazla katkı sağlamaktadır. Halı firmalarında çağ değişiminde oluşabilecek herhangi bir aksaklık tüm iş akışını etkiler. Çünkü çağ değişim esnasında dokuma yapılan tezgâhta üretim durmaktadır. Dokuma sürecinde yaşanan bir gecikme konfeksiyon sürecini etkiler ve nihai olarak doğru zamanda teslimat yapılmamasına etki eder. Çalışmada kullanılan hibrit sinir ağı sayesinde çağ değişim süreleri tahmin edilerek yapılan planlama ile müşteri talepleri zamanında teslim edilerek müşteri memnuniyeti de artırılabilir.

Ayrıca bu çalışma sayesinde, tahminleme konusunda tecrübesi olmayan bir çalışan etkin çağ değişim süresi tahmini yaparak ne kadar sürede değişim olacağını

düşük hata oranı ile öğrenebilir ve buna bağlı olarak siparişin teslim zamanına göre üretilip üretilmeyeceğine karar verebilir.

Son olarak, bu çalışmada ve son zamanlarda literatürde de sıkça kullanılan hibrit sinir ağı yöntemi ile çağ değişim sürelerine sahip verilerinin üretim öncesinde tahminlenmesi ile üretim planlamanın en doğru şekilde yapılarak, verimliliğin arttırılacağı ve buna bağlı olarak üretim maliyetlerinin azaltılacağı öngörülmektedir.

5.2. Öneriler

Bu çalışma sonunda elde edilen sonuçlar daha iyi sonuçların elde edilemeyeceği anlamına gelmemektedir. Her zaman daha iyi bir sonuç elde edilebilir. Bu kapsamda mevcut çalışmaya ek olarak gelecek çalışmalar için aşağıdaki önerilerde bulunulabilir:

- i. Bu çalışmada çağ değişiminde etkili olan temel değişkenler sinir ağına girilmiştir. Değişim sürelerine etki edebilecek birçok değişken olabilir. İleride yapılacak çalışmalarda tezgâhların kullanım yılı, operatörlerin deneyim dereceleri, vardiyalar ve çağ değişimini doğrudan etkileyen diğer etkenler yeni girdiler veri setine eklenerek başarı oranları yeniden ölçülebilir.
- ii. Çalışmanın daha fazla veri ile gerçekleştirilmesi hem verinin doğruluğunu hem de hata payını azaltabilir.
- iii. Yapay sinir ağının girdi sayısının artması gibi nedenlerle başka yöntemlerin kullanılması da göz önüne alınabilir. YSA yöntemi bazı sezgisel modellerle birleştirilerek tahmin sonuçları iyileştirilebilir.
- iv. İşletme içerisinde çağ değişim işlemi dışında üretim kayıplarına neden olan diğer faktörler belirlenip onlar üzerinde de yapılacak çalışmalar ve bunların giderilmesi yönünde atılacak adımlar ile firmanın verimliliği arttırılabilir.

- v. Dokuma birimi halı üretimi sırasında nem oranının değişimi ve statik elektriklenmeden kaynaklı iplik kopuşları meydana gelmektedir. Uygun nem ve hava ortamı sağlanırsa iplik kopuşlarından kaynaklanan makine duruşları da azaltılabilir.
- vi. Dokuma ve çağ değişim personeline verimli dokuma üretimi gerçekleştirilmesi için eğitim verilebilir.
- vii. Optimum makine ayarlarının belirlenmesi için ve makinenin performansı hakkında dokuma operatörlerinden bilgi alınabilir.
- viii. Aynı veya benzer halı tiplerini üreten dokuma makineleri içinde randımanı yüksek olan makinenin ayarları esas alınarak öncelikle en sık duruş yapan makinelerin ayarları kontrol edilerek duruş sayısında azalma sağlanabilir. Bun göre dokuma ustasının makine ayarlamasından önce ve sonra gerçekleşen duruş oranları karşılaştırılarak çalışmalara yön verilebilir.

KAYNAKLAR

- Admuthe, L. S., Apte, S., 2010. Adaptive Neuro-Fuzzy Inference System with Subtractive Clustering: A Model to Predict Fiber and Yarn Relationship. Textile Research Journal, 80:9, 841-846
- Ahmetoğlu, M. E., 2018. Veri Merkezi Sektöründe Satış Tahminleme Modeli ve Özel Kurum Üzerinde Uygulaması. Yüksek Lisans Tezi, Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü, İstanbul
- Aktaş, B., Aydın, C., 2018. Talaşlı İmalat Sektöründe Zaman Serileri Kullanarak Üretim Etkililiğinin Tahmini. Bilişim Teknolojileri Dergisi, 11:4,407-416
- Akyol, D. E., Bayhan G. M., 2007. A Review On Evolution Of Production Scheduling With Neural Networks. Computers. Industrial Engineering, 53, 95-122.
- Anderson, D., McNeill, G., 1992. Artificial Neural Networks Nechnology. Kaman Sciences Corporation, 258: 6, 1-83
- Anonymous, 2018. Van de Wiele Introduces A Revolutionary New Handlook Carpet Quality
- Aslan, E., 2008. Değişik Yapay Sinir Ağı Metotlarının Su Kaynakları Verisinin Uzun Zaman Aralıklı Tahminlerinde Kullanımı. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul
- Azadeh, A., Ghaderi, S.F., Sohrabkhani, S., 2007. Forecasting Electrical Consumption by Integration of Neural Network, Time Series and ANOVA. Applied Mathematics and Computation, 186, 1753–1761
- Baily, D., Thomson, D., 1990. Developing Neural Network Application. AI Expert, 33-41
- Bal, B., 2015. Talep Tahminleme ve Planlama; Perakende Sektörü, E-Ticaret Uygulaması. Yüksek Lisans Tezi, Maltepe Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul

- Bass, B.,2018. Advantages and Disadvantages of Forecasting Methods of Production and Operations Management
- Bayramoğlu, E., 2018. Gaziantep İli Makine Halısı Üretimi. Yüksek Lisans Tezi, Gazi Üniversitesi Güzel Sanatlar Enstitüsü
- Beauduin, C., 2003. Van de Wiele Weave Structure Catalogue. 4-46
- Bhattacharya, S., 1997. A Comparative Study of Different Methods of Predicting Time Series. Yayınlanmamış Yüksek Lisans Tezi, Concordia University, Canada
- BİLEN, G. H., 2011. Termoelektrik Modüllerden Oluşan Bir Sistemin Yapay Sinir Ağları ile Modellenmesi. Yüksek Lisans Tezi, Gazi Üniversitesi, Bilişim Enstitüsü, Ankara
- Bo, Z., 2012. Prediction of NEP of Rotor Spinning Yarn by Means of Intelligent Theory. IERI Procedia, 1, 248-253
- Broomhead, D.S, Lowe, S., 1988. Radial Basis Functions, Multi – Variable Functional Interpolation and Adaptive Networks. Royal Signals and Radar Establishment Memorandum, No.4148
- Caputo, A. C., Pelagagge, P. M., 2008. Parametric and Neural Methods for Cost Estimation of Process Vessels. Int. J. Production Economics, 112, 934–954
- Carpenter, G. A., Grossberg, S.,1987. ART2: Self-Organization of Stable Category Recognition Codes for Analog Input Patterns. Applied Optics, Vol.26, No.3, 4919-4930
- Chen, Z., Wang, J., 2018. GROF: Indoor Localization Using a Multiple-Bandwidth General Regression Neural Network and Outlier Filter. Sensors, 18, 3723, 27s.
- Çelik, B., 2008. Yapay Sinir Ağları Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama. Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul
- Çot, E., 2019. Yapay Sinir Ağı Tekniği Kullanılarak Polipropilen Bcf İpliklerinin Uzama, Mukavemet ve Kıvrımlılık Değerlerinin Tahminlemesi: Tekstil

Sektöründe Bir Uygulama. Yüksek Lisans Tezi, Osmaniye Korkut Ata
Üniversitesi Sosyal Bilimler Enstitüsü, Osmaniye

Demir, V. B., 2016. Yapay Sinir Ağları ile Uçuşlardaki Gecikmelerin Öngörülmesi:
Esenboğa Havalimanında Bir Vaka Çalışması. Yüksek Lisans Tezi, Türk
Hava Kurumu Üniversitesi, Fen Bilimleri Enstitüsü, Ankara

Demuth, H., Beale, M., 2001, Neural Network Toolbox for Use With Matlab. The
Math Works, Inc., 475p.

Doig, G., 1999. Severity of Illness Scoring in the Intensive Care Unit: A Comparison
of Logistic Regression and Artificial Neural Networks. PhD , The University
of Western Ontario

Efendigil, T., Öñüt, S., and Kahraman, C., 2009. A Decision Support System for
Demand Forecasting with Artificial Neural Networks and Neuro-Fuzzy
Models: A Comparative Analysis. Expert Systems with Applications, 36,
6697–6707

Elmas, Ç., 2003. Yapay Sinir Ağları. Ankara: Seçkin Yayıncılık

Estimator for Nonstationary Pattern Recognition Problems. IEEE Transaction on
Neural Networks, 6, 1330 – 1336

Fausett, L.V., Fausett, L., 1994. Fundamentals of Neural Networks: Architectures,
Algorithms, and Applications. Prentice-Hall

Fonseca, D. J., Navarrese, D., 2002. Artificial Neural Networks for Job Shop
Simulation. Advanced Engineering Informatics, 16, 241-246

Fukushima, K., 1986. A Neural Network Model For A Selective Attention In Visual
Pattern Recognition. Biological Cybernetics, 55, 5 – 15

Gharehaghaji, A. A., Palhang, M., Shanbeh, M., 2007. Analysis of Two Modeling
Methodologies for Predicting the Tensile Properties of Cotton-Covered
Nylon Core Yarns. Textile Research Journal, 77:8, 565-571

Grossberg, S., Carpenter, G.A., Reynolds, J.H., 1995. A Fuzzy ARTMAP
Nonparametric Probability

- Guo, J., Sun, J., Zhang, F., Yang, X., 2011. Study on the Intelligent Creel of Advanced Carpet Loom. Advanced Materials Research, 201:203, 1451-1455, Trans Tech Publications, Switzerland
- Gurney, K., 2004. Computers and Symbols versus Nets and Neurons, Dept. Human Sciences, Brunel University, Uxbridge, Middx
- Gülyeşil, S., 2019. Jute Consumption Forecasting: A Case Study In A Carpet Manufacturing. M.Sc. Thesis, University Of Gaziantep, Natural & Applied Sciences, Gaziantep
- Gümüş, V., Soydan, N. G., Şimşek, O., Aköz, M. S., Kırkgöz, M. S., 2013. Yağış-Akış İlişkisinin Belirlenmesinde Farklı Yapay Sinir Ağı Yöntemlerinin Karşılaştırılması. Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 28:1, 37-49
- Güngör, E., 2007. Yapay Sinir Ağları Yardımı ile Makine Arızalarının Önceden Tahmin Edilmesi. Yüksek Lisans Tezi, Kocaeli Üniversitesi, Sosyal Bilimler Enstitüsü
- Gürsoy, A., 2012. Yapay Sinir Ağları Yaklaşımıyla Lastik Kalıbı Maliyetlerinin Tahmin Edilmesi. Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü
- Hawley, D. D., Johnson, J. D., Raina, D., 1990. Artificial neural systems: A new tool for financial decision-making. Financial Analysts Journal, 46:6, 63-72
- Haykin, S., 1999. Neural Networks. A Comprehensive Foundation, Prentice-Hall, New Jersey, 7458, 161-175
- Haykin, S., Haykin, S.S., 2009. Neural Networks and Learning Machines. Prentice Hall
- Hocaoğlu, F. O., Kaysal, K., Kaysa, A., 2015. Yük Tahmini İçin Hibrit (YSA ve Regresyon) Model. K. KAYSAL/APJES, III-II,3 3-39
- Hochreiter, S., Schmidhuber, J., 1997. Long – Short Term Memory. Neural Computation, 9:8, 1735 – 1780

- Jack, L. B., Nandi, A. K., 2002. Fault Detection Using Support Vector Machines and Artificial Neural Networks, Augmented By Genetic Algorithms. *Mechanical Systems and Signal Processing*, 373–390
- Jain, A. K., Mao, J., Mohiuddin, K. M., 1996. Artificial Neural Networks: A tutorial *Computer*, 3, 31-44
- Jain, C.L., Malehorn, J., 2012. *Fundamentals of Demand Planning & Forecasting*. Graceway Publishing Company, New York, 399s.
- Jayalakshmi, T., Santhakumaran, A., 2011. Statistical Normalization and Back Propagation for Classification. *International Journal of Computer Theory and Engineering*, 3:1, 1793-8201
- Kaastra, I., Boyd, M., 1996. Designing a Neural Network for Forecasting Financial and Economic Time Series. *Neurocomputing*, 10:3, 215-236
- Kandırmaz, H.M., Kaba, K., Avcı, M., 2014. Estimation Of Monthly Sunshine Duration In Turkey Using Artificial Neural Networks. *International Journal of Photoenergy*, 1-9
- Karademir, Ö., 2014. Transformatör Üretiminde Üretim Zamanlarının Yapay Sinir Ağları ile Tahmini İçin Bir Çalışma. Yüksek Lisans Tezi, Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü
- Katz, J. O., 1992. Developing Neural Network Forecasters for Trading. *Technical Analysis of Stocks and Commodities*, 58-70
- Kepekçi, E., 2011. Açık İşletme Kamyonları Duruş Sürelerinin Analizi. Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir
- Khashei, M., Bijari, M., 2011. A Novel Hybridization of Artificial Neural Networks and ARIMA Models for Time Series Forecasting. *Applied Soft Computing*, 11, 2664–2675
- Kılıç, S., 2019. Yapay Sinir Ağları ve Regresyon Yöntemleri ile Geri Esneme Tahmini. *BŞEÜ Fen Bilimleri Dergisi*, 6:2, 433-446

- Kızılaslan, R., 2008. Forecasting of Short Term and Mid Term İstanbul Natural Gas Consumption Values by Neural Network Algorithms. Master of Science , Fatih University, Institute of Sciences and Engineering, İstanbul
- Kohonen, T., 1984. Self-Organization and Associative Memory. Springer Series, 8, 89 – 97
- Kohonen, T., Barna, G., 1987. Statistical Pattern Recognition with Neural Networks: Benchmarking Studies. Proc. of The İnt. Joint Conf. on Neural Networks, 1, 1- 66
- Konar, M., 2010. Bulanık Mantık ve Yapay Sinir Ağları Kullanılarak Uçuş Kontrol Sistemlerine Ait Bazı Parametrelerin Hesaplanması. Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri
- Konate', A. A., Pan, H., Khan, N., Yang, J. H., 2014. Generalized Regression and Feed-Forward Back Propagation Neural Networks in Modelling Porosity from Geophysical Well Logs. J Petrol Explor Prod Technol, 5, 157–166
- Krajewski, L.J., Ritzman, L.P., Malhotra, M.K., 2013. Operations Management: Processes and Supply Chains. Pearson
- Kriesel, R., 2005. A Brief Introduction to Neural Networks
- Lee, I., Shaw, M. J., 2000. A Neural-net Approach to Real Time Flow-shop Sequencing. Computers & Industrial Engineering. 38, 125-147
- Lewis, C.D., 1982. Industrial and Business Forecasting Methods. Londra, Butterworths Publishing
- Li, S., Li, Y., Liu, Y., Xu, Y., 2007. A GA-Based NN Approach for Makespan Estimation, Applied Mathematics and Computation, 185, 1003–1014
- Luxhøj, J.T., Riis, J.O., Stensballe, B., 1996. A Hybrid Econometric—Neural Network Modeling Approach for Sales Forecasting. International Journal of Production Economics, 43, 175–192
- Markham, I.S., Rakes, T.R., 1998. The Effect of Sample Size and Variability of Data on The Comparative Performance of Artificial Neural Networks and Regression. Computers and Operations Research, 25, 251–263

- Masters, T., 1993. Practical Neural Network Recipes in C++. Academic Pres, USA
- Mehrotra, K., Mohan, C. K., Ranka, S., 1997. Elements of Artificial Neural Networks. MIT Press
- Meriç, B., Özkal, A., 2002. Döşemelik Kumaş Üreten Bir İşletmede Randıman Analizi. Uludağ Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 7:1, 131-140
- Mombeini, H., Chamzini, A. Y., 2015. Modeling Gold Price via Artificial Neural Network. Journal of Economics, Business and Management, 3:7, 699-703
- Monks, J.G., 1987. Operations Management. McGraw-Hill International Editions, Third Ed., Singapore, 278s.
- Moretti, F., Pizzuti, S., Panzieri, S., Annunziato, M., 2015. Urban Traffic Flow Forecasting Through Statistical and Neural Network Bagging Ensemble Hybrid Modeling. Neurocomputing, 167, 3–7
- Ntungo, C., Boyd, M., 1998. Commodity Futures Trading Performance Using Neural Network Models Versus ARIMA Models. Journal of Futures Markets: Futures, Options, and Other Derivative Products, 18:8, 965-983
- Orhunbilge, N., 1996. Uygulamalı Regresyon ve Korelasyon Analizi. İstanbul Üniversitesi İşletme Fakültesi Yayını, Yayın No:267, İstanbul
- Öztemel, E., 2003. Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul
- Özyirmidokuz, E., 2009. Veri Madenciliği Tekniklerini Kullanarak İmalat Verilerinin Modellenmesi ve Analizi. Dokora Tezi, Erciyes Üniversitesi Sosyal Bilimler Enstitüsü, Kayseri
- Park, E., S.J. Kwon, 2017. What Motivations Drive Sustainable Energy-Saving Behavior?: An Examination in South Korea. Renewable and Sustainable Energy Reviews, 79, 494-502
- Pektaş, M. S., 2018. Application Of Knn-Grnn Algorithm For Liquid Holdup Determination In Two-Phase Flow. M.Sc. Thesis, Istanbul Technical University, Science Engineering and Technology, İstanbul

- Perez,–Ortiz, J. A., Gers, F. A., Eck, D., Schmidhuber, J., 2003. Kalman Filters Improve LSTM Network Performance in Problems Unsolvable by Traditional Recurrent Nets. *Neural Networks*, 16, 241 – 250
- Peško, I., MuIenski, V., Šešlija, M., Radovic, N., Vujkov, A., Bibic, D., Krklješ, M., 2017. Estimation of Costs and Durations of Construction of Urban Roads Using ANN and SVM. *Hindawi Complexity*, 13s.
- Pour, A. N., Tabar, B. R., Rahimzadeh, A., 2008. A Hybrid Neural Network and Traditional Approach for Forecasting Lumpy Demand. *International Journal of Industrial and Manufacturing Engineering*, 2:4, 1028-1034
- Rojas, R., 1996. *Neural Networks*. Berlin, Springer-Verlag
- Sabuncuoğlu, İ., Gürgün, B., 1996. A Neural Network Model for Scheduling Problems. *European Journal of Operational Research*, 93, 288-299
- Sağıroğlu, Ş., Beşdok, E., Erler, M., 2003. *Mühendislikte Yapay Zekâ Uygulamaları I: Yapay Sinir Ağları*. *Ufuk Kitap Kırtasiye Yayıncılık, Kayseri*
- Saraç, T., 2004. *Yapay sinir ağları*. *Basılmamış Seminer Projesi, Gazi Üniversitesi Endüstri Mühendisliği Bölümü Anabilim Dalı, Ankara*
- Scholkopf, B., Smola, A. J., Muller, K. R., 1997. Kernel Principal Component Analysis., *Advances in Kernel Methods: Support Vector Learning*. MIT Press, Cambridge, 327-352
- Seyam, A. F. M., 2019. *Innovation in Weaving at ITMA 2019*. NC State Wilson College of Textiles, Barcelona
- She, J., Zou, K., Wen, J., Shi, R., 2014. Research on Control System of Intelligent Creel Multi-Robot. *Applied Mechanics and Materials*, 541:542, 1115-1119, Trans Tech Publications, Switzerland
- Simpson, P. K., 1990. *Neural Networks Theory, Technology and Applications*. NewYork: The Institute of Electrical and Electronics Engineers Press

- Sodaner, D., 2014. Hibrit Yapay Sinir Ağları Yaklaşımı ile Kredi Skorlama. Yüksek Lisans Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü
- Specht DF., 1991. A general regression neural network. IEEE Transactions on Neural Networks, 2:6, 568-576
- Sridhar, B., Wang, Y., Klein, A., Jehlen, R., 2009. Modeling Flight Delays and Cancellations at the National, Regional and Airport Levels in the United States. Eighth USA/Europe Air Traffic Management Research and Development Seminar (ATM2009), California
- Sütçü, E., 2018. Kaynaklı İmalat Operasyon Sürelerinin Matlab Yapay Sinir Ağları ile Tahmin Edilmesi. Gazi Mühendislik Bilimleri Dergisi, 4:1, 16-24
- Symeonidis, K., 2000. Hand Gesture Recognition Using Neural Networks. School of Electronic and Electrical Engineering, Master of Science in Multimedia Signal Processing Communications
- Şen, Z., 2004. Yapay Sinir Ağları ve İlkeleri. Su Vakfı Yayınları, İstanbul
- Tarassenko, L., 1998. A Guide to Neural Computing Applications. London, UK: Hodder Arnold Publication
- Taşyürek, M., Çelik, M., 2020. Akıllı Durak Sistemindeki Araç Seyahat Sürelerinin Birleşik Yapay Sinir Ağları Kullanarak Tahmini. Avrupa Bilim ve Teknoloji Dergisi, Özel Sayı, 72-79
- Tosun, S., 2007. Sınıflandırmada Yapay Sinir Ağları ve Veri Madenciliği Karşılaştırması: Öğrenci Başarıları Üzerine Bir Uygulama. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul
- Turaç, A., 2020. Yapay Sinir Ağları ile Tahminleme: Türkiye'nin İhracatının Tahmini Üzerine Bir Uygulama. Yüksek Lisans Tezi, Gebze Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, Gebze
- Türker, E., 2016. A Research on Estimation of The Weave Fabric Properties with The Artificial Neural Networks. Tekstil ve Konfeksiyon. 27:1, 10-21
- Türkiye İhracatçılar Meclisi Halı Sektör Raporu, 2020

- Ünal, İ., Sözer, S., Kabaş, Ö., Çetin, S., Topakcı, M., 2016. Üç Farklı Yapay Sinir Ağı Yöntemi Kullanılarak Toprak Penetrasyon Direnci Tahmini. Tarım Makinaları Bilimi Dergisi, 12:2, 95-102
- Wang, G., Hao, J., Ma, J., Jiang, H., 2011. A Comparative Assessment of Ensemble Learning for Credit Scoring, Expert Systems with Applications, 38, 223-230
- Wasserman, P. D., 1993. Advanced Methods in Neural Computing. John Wiley & Sons, Inc.
- Widrow, B., Lehr, M. A., 1990. 30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation. Proceedings of the IEEE, 78:9, 1415-1442
- Widrow, B., Hoff, M. E., 1960. Adaptive Switching Circuits. No. TR-1553-1
- Witt, S. F., Witt, C. A., 1995. Forecasting Tourism Demand: A Review of Empirical Research. International Journal of forecasting, 11:3, 447-475
- Yakut, E., 2012. Veri Madenciliği Tekniklerinden C5.0 Algoritması ve Destek Vektör Makineleri ile Yapay Sinir Ağlarının Sınıflandırılma Başarılarının Karşılaştırılması: İmalat Sektöründe Bir Uygulama. Doktora Tezi, Atatürk Üniversitesi, Sosyal Bilimleri Enstitüsü, Erzurum
- Yakut, E., Elmas, B., Yavuz, S., 2014. Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 19:1, 139-157
- Yurtoğlu, H., 2005. Yapay Sinir Ağları ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği. DPT Yayınları, Ankara, 6, 2683
- Zhang, G., Patuwo, B. E., Hu, M. Y., 1998. Forecasting with Artificial Neural Networks: The State of The Art. International Journal of Forecasting, 14:1, 35-62
- Zhang, G., Patuwo, B. E., Hu, M. Y., 1998. Forecasting with Artificial Neural Networks: The State of The Art. International Journal of Forecasting, 14:1, 35-62

- Zhang, G.P., Patuwo, B.E., Hu, M.Y., 2001. A Simulation Study of Artificial Neural Networks for Nonlinear Time-Series Forecasting. *Operations Research*
- Zhang, G.P., Qi, M., 2005. Neural Network Forecasting for Seasonal and Trend Time Series. *European Journal of Operational Research*, 160, 501–514





ÖZGEÇMİŞ

İlk, orta ve lise öğrenimini Adana’da tamamladı. 2009 yılında başladığı Gaziantep Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü’nden 2014 yılında mezun oldu. Eylül 2017’de Çukurova Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalında Tezli Yüksek Lisans eğitimine başladı.







EKLER



EK 1. Tasarlanan YSA modeli

