



T.C.
KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY ZEKA MODELLERİNİ KULLANARAK
SÜREÇ İYİLEŞTİRMEYE YÖNELİK BİR ÇALIŞMA:
ŞÖNİL KUMAŞ ÖRNEĞİ**

AYŞE DİDEM EROL ERKEK

**DOKTORA TEZİ
TEKSTİL MÜHENDİSLİĞİ ANABİLİM DALI**

KAHRAMANMARAŞ 2025

T.C.
KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA MODELLERİNİ KULLANARAK
SÜREÇ İYİLEŞTİRMEYE YÖNELİK BİR ÇALIŞMA:
ŞÖNİL KUMAŞ ÖRNEĞİ

AYŞE DİDEM EROL ERKEK

DOKTORA TEZİ

TEKSTİL MÜHENDİSLİĞİ ANABİLİM DALI

KAHRAMANMARAŞ 2025

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada, alıntı yapılan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

Ayşe Didem EROL ERKEK

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

**YAPAY ZEKA MODELLERİNİ KULLANARAK SÜREÇ İYİLEŞTİRMEYE
YÖNELİK BİR ÇALIŞMA: ŞÖNİL KUMAŞ ÖRNEĞİ
(DOKTORA TEZİ)**

AYŞE DİDEM EROL ERKEK

ÖZET

Bu tez çalışmasında, farklı şönil iplik ile şönil kumaş parametreleri ve şönil kumaş görüntü özellikleri kullanılarak kumaşların bazı performans özelliklerinin yapay zeka yöntemleri ile tahmin edilmesi amaçlanmıştır. Bu çalışma için hav uzunluğu, iplik numarası ve lif tipi parametreleriyle farklı şönil iplikler üretilmiştir. Üç farklı lif tipi kullanılmıştır: polyester, akrilik ve viskon. Her lif tipi için dört farklı iplik numarası ve her iplik numarası için dört farklı hav uzunluğu kullanılmıştır. Böylece 48 farklı iplikten 48 dokuma kumaş elde edilmiştir. Tahmin edilen performans özellikleri arasında atkı-çözgü yönünde kopma mukavemeti ve aşınma direnci yer almıştır; bu özellikler çıktı verilerini oluşturmuştur. Birinci durumda girdi verileri olarak hav uzunluğu, iplik numarası, lif tipi, atkı sıklığı, kumaş kalınlığı ve kumaş ağırlığı kullanılmıştır. İkinci durumda ise elde edilen kumaş görüntülerinden yüzey özellikleri çıkarılmış ve bunlar girdi verileri olarak kullanılmıştır. Yapay Sinir Ağı (YSA) modellerini geliştirmek için MATLAB'daki sinir ağı araç kutusu kullanılmıştır. Üç performans özelliğini tahmin etmek için farklı ağ yapıları kullanılmış, böylece daha doğru sonuçlar elde edilmesi amaçlanmıştır. Birinci durumda ve ikinci durumda elde edilen YSA modellerinin başarı oranları belirlenmiş ve karşılaştırma yapılmıştır. Deney ve tahmin sonuçları arasındaki R değerlerine bakıldığında; birinci yöntemde 0.98, 0.86, 0.93 iken ikinci yöntemde 0.78, 0.73, 0.68 olduğu görülmüştür. Birinci durumda kullanılan girdi verileri ile kurulan modellerde diğerine nazaran daha yüksek tahminleme başarıları elde edilmiştir. Ancak ikinci durumda sadece görüntülerden çıkarılan özellikler kullanılmasına rağmen tahminleme başarısının göz ardı edilemeyecek kadar iyi olduğu görülmüştür.

Anahtar Kelimeler: Şönil iplik, kopma mukavemeti, aşınma direnci, yapay sinir ağı, görüntü işleme

Kahramanmaraş Sütçü İmam Üniversitesi
Fen Bilimleri Enstitüsü
Tekstil Mühendisliği Ana Bilim Dalı, Ocak/2025

Danışman: Prof. Dr. Suat ÇETİNER

İkinci Danışman: Prof. Dr. Halil İbrahim ÇELİK

Sayfa sayısı: 100

**A STUDY ON PROCESS IMPROVEMENT USING ARTIFICIAL
INTELLIGENCE MODELS: EXAMPLE OF CHENILLE FABRIC
(Ph.D. THESIS)**

AYSE DIDEM EROL ERKEK

ABSTRACT

In this thesis study, it is aimed to predict some performance properties of fabrics with artificial intelligence methods by using different chenille yarn and chenille fabric parameters and chenille fabric image features. For this study, different chenille yarns were produced with parameters of pile length, yarn count and fiber type. Three different fiber types were used: polyester, acrylic and viscose. Four different yarn counts were used for each fiber type and four different pile lengths were used for each yarn count. Thus, 48 woven fabrics were obtained from 48 different yarns. Predicted performance properties included breaking strength in weft-warp direction and abrasion resistance; these features formed output data. In the first case, pile length, yarn count, fiber type, weft density, fabric thickness and fabric weight were used as input data. In the second case, surface features were extracted from obtained fabric images and these were used as input data. The neural network toolbox in MATLAB was used to develop Artificial Neural Network (ANN) models. Different network structures were used to estimate three performance features, thus aiming to obtain more accurate results. The success rates of ANN models obtained in first case and second case were determined and compared. When looking R values between experimental and prediction results; while it was 0.98, 0.86, 0.93 in first method, it was 0.78, 0.73, 0.68 in second method. In first case, higher prediction successes were achieved in models built with input data used compared to the other. However, in second case, although only features extracted from images were used, prediction success was seen to be too good to be ignored.

Keywords: Chenille yarn, breaking strength, abrasion resistance, artificial neural network, image processing

Kahramanmaraş Sütcü Imam University
Institute in Science
Department of Textile Engineering, January/2025

Supervisor: Prof. Dr. Suat ÇETİNER

Co-supervisor: Prof. Dr. Halil İbrahim ÇELİK

Page number: 100

TEŞEKKÜR

Lisansüstü çalışmaların doğasından gelen ve oldukça vakit alan bu süreçte, normal şartlar altında ilgisini, bilgisini ve desteğini esirgemeyen, ancak buldukları şehirler itibariyle son yüzyılın en büyük felaketi olarak nitelendirilen afeti yaşamalarına rağmen desteklerini sürdürmeleri nedeniyle teşekkür kelimesinin yeterli kalmayacağı danışman hocam Sayın Prof. Dr. Suat ÇETİNER ve eş danışman hocam Sayın Prof. Dr. Halil İbrahim ÇELİK'e,

İplik üretiminde desteklerini esirgemeyen Gaziantep'te bulunan MELİKE TEKSTİL'e; kumaş üretimi ve üretilen kumaşlara uygulanan performans testleri için kapılarını açan Kahramanmaraş'ta bulunan KİPAŞ HOLDİNG'e ve süreci organize eden Sayın Gülay KAHRAMAN'a; kumaş üretim sürecinde ve performans testlerinin uygulanmasında iletişimde olduğumuz, ayrıca bahsi geçen felaket nedeniyle bütün çalışmalarımın fabrikanın aldığı hasarda kaybolduğu, kaybedilen canları düşünerek belki de doktora sevdamdan vazgeçme düşüncesine girdiğim yaklaşık üç aylık bir dönemde çalışmalarımın bulunması için emek sarfeden ve bulundu haberini verip tekrar umut etmeme vesile olan Ayşenur TARAKÇI'ya,

Gerek Gaziantep'te kaldığım süreçte laboratuvar çalışmalarında vermiş olduğu desteklerle, gerekse uzaktan yapmış olduğu bilgi paylaşımlarıyla vaktini ayıran Elif GÜLTEKİN'e,

Kaybolan çalışmalarımın bulunmasıyla yaşadığım şehre ulaştırılmasında hem kendisi hem ailesi hem de tanıdıkları aracılığıyla her daim destek olan arkadaşım Feride TUĞRUL'a,

Kıymetli zamanlarını ayırıp çalışmamı değerlendiren, tez jürisinde bulunan hocalarım Sayın Prof. Dr. Yasemin KORKMAZ, Sayın Prof. Dr. Mehmet DAŞDEMİR, Sayın Prof. Dr. H. Kübra KAYNAK ve Sayın Doç. Dr. İbrahim KARTERİ'ye,

2211-A Genel Yurtiçi Doktora Burs Programıyla vermiş olduğu destekten dolayı TUBİTAK ailesine,

Hayatımın her aşamasında yanımda olup, maddi manevi desteklerini esirgemeyen, tez çalışmalarım da büyük fedakarlıklarda bulunan ve haklarını ödeyemeyeceğim değerli annem ve babama; kendi başına yaşamdan çıkıp sorumluluğun gerçek anlamda ne olduğunu, zamanın kıymetini bilip zamanı yönetmenin de bir meziyet olduğunu ve her türlü olumsuzluğa rağmen gülümsemek gerektiğini öğrenip olgunlaşmamı sağlayan ve hayatıma yeni anlamlar katan sevgili eşim ve canım yavruma; çocukların özellikle savaş gibi hiçbir haklı gerekçesi olmayan bir tasavvurla ölüme mahkum edilmesinin sonlandırıldığı bir dünya dileklerle sonsuz teşekkürlerimi sunarım.

Ayşe Didem EROL ERKEK

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
SİMGELER VE KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
1.1. Yapay Zekanın Tekstilde Kullanılabileceği Alanlar.....	4
1.2. Tez Çalışmasının Amacı ve Kapsamı	7
2. TEKSTİL SEKTÖRÜNDE YAPAY ZEKA UYGULAMALARI	9
2.1. Lif ve İplik Üretiminde YZ Uygulanması	9
2.2. Kumaş Üretiminde YZ Uygulanması	11
2.2.1. Kumaş özelliklerini tahmin etme	11
2.2.2. Renk çözeltileri	14
2.2.3. Kumaş hatası tespiti	15
2.3. Giysi İmalatında YZ Uygulanması	18
2.3.1. Dikiş performansı.....	18
2.3.2. Bilgisayar destekli tasarım sistemleri.....	20
2.3.3. Üretim planlama ve kontrol	22
2.3.4. Son giysi kontrolü	23
2.3.5. Tedarik zincirindeki uygulamalar	24
2.3.6. Perakendecilikteki uygulamalar	25
3. ÖNCEKİ ÇALIŞMALAR	27
3.1. Şönil İplik ve Şönil Kumaşla İlgili Çalışmalar	27
3.2. Tekstilde Yüzey Özelliği Çıkarmayla İlgili Çalışmalar.....	30
3.3. Tekstilde Yapay Sinir Ağları ile İlgili Çalışmalar	35
4. YAPAY SİNİR AĞLARI	40
5. DERİN ÖĞRENME	42
5.1. Önceden Eğitilmiş Derin Sinir Ağları.....	43
5.1.1. GoogLeNet.....	45
5.1.2. AlexNet	46
5.1.3. ResNet	47
5.1.4. VGG16 ve VGG19.....	47

6. ŞÖNİL İPLİK VE ŞÖNİL KUMAŞ	48
7. MATERYAL VE METOT	52
7.1. Materyal	52
7.2. Metot.....	54
7.2.1. Performans testleri	54
7.2.2. Görüntü alma sistemi	54
7.2.3. MATLAB derin öğrenme ağ düzenlemesi	55
7.2.4. Yüzey özelliklerinin çıkarılması	60
7.2.5. Değerlendirmelerde kullanılan istatistiksel araçlar	62
7.2.6. Yapay sinir ağı (YSA) tasarımı.....	63
7.2.6.1. İplik ve kumaş verilerini kullanarak tahminleme için YSA modelleri	63
7.2.6.2. Kumaş yüzey özellikleri kullanarak tahminleme için YSA modelleri	70
8. BULGULAR VE TARTIŞMA	74
8.1. Performans Test Sonuçları.....	74
8.2. YSA 1, YSA 2 ve YSA 3 Modelleri Öğrenme Performansı	75
8.3. YSA/R 1, YSA/R 2 ve YSA/R 3 Modelleri Öğrenme Performansı	77
8.4. Oluşturulan Modellerin Tahminleme Sonuçları	80
8.4.1. Atkı yönünde kopma mukavemeti tahminleme sonuçları (YSA 1 ve YSA/R 1)	81
8.4.2. Çözgü yönünde kopma mukavemeti tahminleme sonuçları (YSA 2 ve YSA/R 2)	82
8.4.3. Aşınma direnci tahminleme sonuçları (YSA 3 ve YSA/R 3)	83
9. SONUÇLAR.....	85
KAYNAKLAR.....	88
ÖZGEÇMİŞ	99

SİMGELER VE KISALTMALAR DİZİNİ

YZ	: Yapay Zeka
SA	: Sinir Ağı
BM	: Bulanık Mantık
GA	: Genetik Algoritma
ES	: Evrim Stratejisi
YBS	: Yapay Bağışıklık Sistemi
ÇES	: Çok Etmenli Sistem
BSA	: Bulanık Sinir Ağı
YSA	: Yapay Sinir Ağı
CAD	: Bilgisayar Destekli Yazılım/Tasarım
BM	: Bulanık Mantık
KES	: Kawabata Değerlendirme Sistemi
ÜPK	: Üretim, Planlama ve Kontrol
GY	: Geri yayılım
TZY	: Tedarik Zinciri Yönetimi
PES	: Poliester
PET	: Polietilen Tereftalat
OMYH	: Ortalama Mutlak Yüzdesele Hata

ŞEKİLLER DİZİNİ

Şekil 1.1. Tekstil lojistik zinciri (mavi diyagram) ve yapay zeka ile güçlendirme fırsatları (yeşil baloncuklar)	5
Şekil 2.1. Yapay zeka ile incelenen farklı kumaş hataları (a) atık lif, (b) çözgü yüzmesi, (c) geri çekme, (d) delik, (e) sökük ve (f) kapalı makine örme hatası (Ngan ve ark., 2011).....	16
Şekil 2.2. Tipik bir otomatik kontrol sisteminin konfigürasyonu	17
Şekil 4.1. Yapay sinir ağı yapısı	40
Şekil 5.1. Önceden eğitilmiş derin ağların kullanımı	45
Şekil 5.2. GoogLeNet ağ mimarisi	46
Şekil 5.3. AlexNet ağ mimarisi	46
Şekil 6.1. Fantezi ipliğin temel yapısı	48
Şekil 6.2. Şönül iplik yapısı	49
Şekil 6.3. Şönül iplik makinesi	50
Şekil 6.4. Şönül iplik makinesi çalışma prensibi	50
Şekil 6.5. Şönül iplik ve şönül kumaş görüntüleri	51
Şekil 7.1. Şönül kumaşların a) kalınlık ve b) gramaj ölçümleri.....	54
Şekil 7.2. Şönül kumaşlardan görüntü alma a) ışıklandırılmış kabin düzeneği b) AMCap programı c) mikroskop kamera d) polyester kumaş e) akrilik kumaş f) viskon kumaş.....	55
Şekil 7.3. Resnet101 ağında “fully connected” katmanını değiştirme	56
Şekil 7.4. Resnet101 ağında “classification” katmanını değiştirme.....	57
Şekil 7.5. Resnet101 ağında veri ekleme.....	57
Şekil 7.6. Resnet101 ağında verilerin sınıflandırılması.....	58
Şekil 7.7. Resnet101 ağında eğitim seçenekleri	59
Şekil 7.8. Modifiye Resnet101 ağının eğitim grafiği	60
Şekil 7.9. Yüzey özelliği çıkarma akış diyagramı	61
Şekil 7.10. Verilerle oluşturulan yapay sinir ağı modeli	65
Şekil 7.11. YSA 1’i oluşturmak için gerekli parametreler	67
Şekil 7.12. YSA 1 mimarisi.....	67
Şekil 7.13. YSA 1 eğitim parametreleri	68
Şekil 7.14. YSA 2 mimarisi.....	68
Şekil 7.15. YSA 2 eğitim parametreleri	69

Şekil 7.16. YSA 3 mimarisi.....	69
Şekil 7.17. YSA 3 eğitim parametreleri	70
Şekil 7.18. YSA/R 1 mimarisi	72
Şekil 7.19. YSA/R 2 mimarisi	72
Şekil 7.20. YSA/R 3 mimarisi	73
Şekil 8.1. YSA 1 regresyon sonuçları	76
Şekil 8.2. YSA 2 regresyon sonuçları	76
Şekil 8.3. YSA 3 regresyon sonuçları	77
Şekil 8.4. YSA/R 1 regresyon sonuçları.....	78
Şekil 8.5. YSA/R 2 regresyon sonuçları.....	79
Şekil 8.6. YSA/R 3 regresyon sonuçları.....	80
Şekil 8.7. Modelleme akış diyagramı	80
Şekil 8.8. Atkı yönünde kopma mukavemeti için deneysel ve tahmin değerlerinin doğrusal regresyonu.....	82
Şekil 8.9. Çözgü yönünde kopma mukavemeti için deneysel ve tahmin değerlerinin doğrusal regresyonu.....	83
Şekil 8.10. Aşınma direnci için deneysel ve tahmin değerlerinin doğrusal regresyonu.....	84

ÇİZELGELER DİZİNİ

Çizelge 4.1. Yapay sinir ağı uygulama alanları.....	41
Çizelge 5.1. Önceden eğitilmiş ağı kullanma ile yeni bir derin ağı oluşturma arasında farklar	43
Çizelge 7.1. Üretilen şönil iplik ve şönil kumaş özellikleri.....	53
Çizelge 7.2. Modifiye edilmiş derin sinir ağıları sonuç tablosu	60
Çizelge 7.3. OMYH değerlerinin yorumlanması.....	62
Çizelge 7.4. Ağı yapısını belirlemede kullanılan deneme kombinasyonları - I.....	66
Çizelge 7.5. Ağı yapısını belirlemede kullanılan deneme kombinasyonları - II	71
Çizelge 8.1. Performans test sonuçları	74
Çizelge 8.2. Atkı yönünde kopma mukavemeti tahmin sonuçları.....	81
Çizelge 8.3. Çözümlü yönünde kopma mukavemeti tahmin sonuçları	83
Çizelge 8.4. Aşınma direnci tahmin sonuçları.....	84

1. GİRİŞ

Tekstil imalat sanayi, tarihin ilk dönemlerinde başlayan geleneksel üretimini sanayi devrimi ile birlikte kitle üretimine çevirmiş ve ülkelerin sanayileşme evrelerinde vazgeçilmez bir sanayi dalı olmuştur. Günümüzde ise teknolojik gelişmelerin de desteği ile çok çeşitli ve fonksiyonel ürünleri ile tüm ülkeler için önemli bir sanayi kolu olmayı sürdürmektedir. Tekstil üretimi, lif ve iplikten üretilen çoğunlukla esnek olan malzemelerin üretimi ile bu malzemelerin şekillendirmesi ve nihai mamul haline getirilmesidir. Bu tanıma göre sektör elyaf hazırlama, iplik, dokuma, örme, boyama, baskı, terbiye, kesim ve dikiş üretim işlemlerini içermektedir (Kalkınma Ajansları Genel Müdürlüğü, 2021).

Tekstil ve hazır giyim sanayi 1970'lerin başından itibaren önemli gelişmeler kaydetmiş, günümüzde bu sektöre ait tasarım ve kişisel zevklere göre kullanımın belirleyici olması sebebiyle çok hızlı büyüyen sektörler arasındaki yerini almıştır. Ülkelerin refah düzeylerinin artması, konut inşasındaki yükseliş, turizm sektörünün hızla ivme kazanması ve destinasyon turizminin gelişmesi, tüm alt sektörleriyle beraber tekstil sektörüne olan ihtiyacı artırmış ve sektör hızla büyümüştür. Bu büyüme ülkemizde de önemli bir yer teşkil etmektedir. TÜİK 2021 verilerine göre, 2019 yılında Türkiye'nin halı, hazır giyim ve konfeksiyon, tekstil ve hammaddeleri ihracatı toplam ülke ihracatının %16'sını oluştururken, 2020 yılında aynı gruptaki ihracat toplam ülke ihracatının %18'ini oluşturmuştur (Kalkınma Ajansları Genel Müdürlüğü, 2021).

Dünya nüfusu sürekli arttıkça giyim, moda aksesuarları ve diğer tekstil ürünlerine olan talep de artmaktadır. Artan küresel talep, ağırlıklı olarak gelişmekte olan ülkelerde bulunan tekstil ve giyim üreticileri tarafından karşılanmaktadır. Küreselleşmeye ek olarak gelişmiş ülkelere ucuz giyim talebi ve artan işgücü maliyeti, bu ürünlerin imalatının gelişmekte olan ülkelere kaymasına neden olmuştur (Nayak ve Padhye, 2018). Hali hazırda ülkemiz de tekstil ihtiyacının karşılanmasında önemli bir konumda yer almaktadır. Euratex 2021 verilerine bakıldığında, Türkiye, 2020 yılında en fazla tekstil ihracatı yapan ülkeler sıralamasında 5. ülke ve en fazla hazır giyim ve konfeksiyon ihracatı yapan ülkeler sıralamasında 4. ülke olmuştur. Ancak bütün bu gelişmelere rağmen sektörde hızla değişen trendler ve moda algısı bir taraftan üreticiyi zorlarken diğer taraftan müşterinin kalite beklentilerini artırmaktadır. Üreticiler, bu değişkenliğe hızlı ve ekonomik şekilde uyum sağlamak ve aynı zamanda müşteri memnuniyeti kazanmak amacıyla çeşitli stratejiler geliştirmek durumunda kalmıştır.

Kaliteli ürünlere olan talebin artması ile birlikte, tekstil endüstrisinin işçilik ve üretim maliyetlerini en aza indirerek, müşteri tercihlerine göre ürünler sunmak için otomasyon ve yapay zekayı benimsemesine yol açmıştır. Tekstil endüstrisindeki proseslerin bir kısmı, insan işlevlerini daha verimli ve çok daha hızlı bir zaman diliminde yerine getiren yapay zeka ile otomatik hale getirilmeye çalışılmaktadır. Bu şekilde insan müdahalesi minimum hale getirilerek, üretim ve kalite konusunda belirli standartlar yakalanması amaçlanmaktadır.

Tekstil üretim ayaklarından biri olan iplik ve kumaş üretimi hem Dünya hem de Türkiye tekstil sektörü ticaretinde önemli bir yere sahiptir. Günümüzde doğal ya da yapay kaynaklı birçok iplik çeşidi üretimi yapılmaktadır. Bunlar arasında fantezi iplik üretimi de bulunmaktadır. Fantezi iplik üretimi, muline, bukle, lup, kıvrım, nopeli, düğüm, sanat, gimp, şönil, makarna, frize ve şantuklu iplik gibi çeşitleri kapsamaktadır. Bu çeşitteki iplikler klasik iplik üretime göre birtakım farklılıklar içermektedir. Çalışmaya konu olan şönil ipliklerin üretimi de bu farklılıklar nedeniyle karmaşıktır. Şönil ipliklerden üretilen şönil kumaşların kalite parametrelerini belirlemek de bu nedenle zorlaşabilmektedir.

Fantezi bir iplik olan şönil iplik üretiminde geleneksel iplik üretimine göre daha fazla detay bulunmaktadır. Bağ iplikleri ve hav ipliklerinden oluşan şönil ipliği şönil iplik makinelerinde üretilmektedir. Geleneksel ipliğe göre karmaşık yapısı, üretimde etkin parametrelerin etkisinin anlaşılmasını zorlaştırmaktadır. Geleneksel iplik üretiminde lif tipi, lif uzunluğu, lif inceliği, iplik numarası, iplik katı ve iplik bükümü gibi parametreler etkili iken (Kotb, 2012; Kulkarni, 2022); şönil iplik üretiminde bunların yanı sıra hav yoğunluğu, hav ve bağ iplik tipleri, hav uzunluğu gibi parametreler de etkili olabilmektedir. Şönil iplik parametrelerinin şönil ipliğinden üretilen kumaşların performans özelliklerine etkisi daha önceki çalışmalarda da görülmüştür. Ayrıca bu çalışmaların bir kısmında kumaş üretim parametreleri de dikkate alınmış ve bu şekilde performans özellikleri araştırılmıştır (Çeven ve ark., 2007; Babaarslan ve Telli, 2013). Şönil iplik ve kumaş üretiminde kalite standardını yakalamak ve müşteri memnuniyetini elde edebilmek amacıyla, şönil iplik ve kumaş üretiminde karmaşık sorunları çözmede etkili olan yapay zeka yöntemlerini kullanma ve olası çözümleri araştırma düşüncesini ortaya çıkarmıştır.

Bilgi teknolojisi çağında, yapay zeka (YZ) mühendislik, fizik, tıp ve yönetim alanında devrim yaratmıştır. YZ, sezgisel ve akıllı özellikleri sayesinde çeşitli sorunlara üstün çözümler sunabilmektedir. YZ yardımıyla kalitenin iyileştirilmesi, verimliliğin artırılması

ve üretim maliyetinin düşürülmesi gibi önemli sonuçlar elde edilebilmektedir (Shamey ve Hussain, 2003; Wong ve ark., 2004).

YZ, insan zekasının özelliklerini ve insanın duyuşsal yeteneklerini simüle edebilen bir bilgisayar bilimi alanıdır. Yapay zeka sistemleri, sezgisel ve akıllı yapıları nedeniyle klasik sistemlere göre daha üstün çözümler sunabilmektedir. Geleneksel bilgisayarlar öğrenme yeteneğinden yoksundur ve bilgisayarların yalnızca programlandıkları koşullar altında çalışmaları onları kısıtlamaktadır. Temelde bilgisayarların sınırlandıkları noktalar şu şekilde özetlenebilir (Nayak ve Padhye, 2018):

- Zeki değiller
- Kendilerinin farkında değiller
- Çevreyi bilmiyorlar

Buna karşılık, insanlar bilgisayarlara kıyasla yavaş ve güvenilmez olsalar da, sonsuz çeşitlilikteki problemleri çözmelerini sağlayan zeka ve anlayışa sahiptirler. YZ, insan zekasını simüle edebilen ve buna göre çalışan makinelerin yaratılmasıdır. YZ'nin sezgisel ve akıllı doğası, klasik tekniklere göre üstün çözümler sağlamaya yardımcı olmaktadır.

Yaklaşık otuz yıl önce, özellikle hazır giyim üretimindeki odak nokta, şimdilerde çok fazla değişen üretim hacmindeydi. Son zamanlardaki odak noktası ise, üretim hacmine ek olarak iyi kalite, düşük maliyet, istatistiksel süreç kontrolü, tam zamanında üretim ve bilgisayarla tümleşik üretimdir. YZ, tekstil tasarımında, üretim planlamasında, kalite kontrolde, satış tahmininde ve tedarik zincirinde giderek daha fazla kullanılmaktadır. Yapay sinir ağı (YSA), bulanık mantık (BM), genetik algoritma (GA), yapay bağışıklık sistemi (YBS) ve çok etmenli sistem (ÇES) gibi bir dizi YZ tekniğı tekstil imalatında kullanılmaktadır. YSA insan sinir sisteminin yapısına benzer şekilde çalışmaktadır. Geleneksel tekniklerin tatmin edici sonuçlar vermediğı veya modelleme performansındaki küçük iyileştirmelerin verimlilikte önemli bir fark yaratabileceğı durumlarda uygulanmaktadır. BM, davranışın doğrusal olmadığı durumlarda kullanılmaktadır. BM'de bulanık çıkarım sistemi uygulanırken eğer/ise mantığıyla hareket edilir. Biyolojik evrimi taklit eden doğal seçilim sürecine dayalı bir yöntem olan GA ile hem kısıtlı hem de kısıtlamasız optimizasyon problemleri çözülebilmektedir. GA'da bireysel çözümlerden oluşan bir popülasyon, algoritma tarafından tekrar tekrar değıştirilir. GA, kalıtım, mutasyon, seçim ve çaprazlama gibi doğal evrimden ilham alan teknikleri kullanarak optimizasyon sorunlarına çözümler üreten evrimsel algoritmaların bir parçasıdır. YBS, GA ile benzerlik göstermektedir, ancak

GA'da olan bazı operatörler bu sistemde bulunmamaktadır. ÇES ise etkileşim ve iş birliği özelliklerine sahip birden fazla etkileşimli akıllı araçından oluşur ve araçların, bilginin eş zamanlı olarak alınması, aktarılması ve iletilmesi konusunda otonom işlevlerle farklı görevleri yerine getirmesine yardımcı olabilmektedir.

Bir YZ tekniği olan ve bu çalışmada kullanılan YSA'ların çalışma sistemi biyolojik sinir ağlarına benzemektedir. Bir sinir ağı, nöronlar, birimler, hücreler ve düğümler adı verilen işlem elemanlarından oluşur. Her nöron, diğer nöronlardan ve/veya kendisinden, her biri ilişkili bir ağırlığa sahip bağlantılar alır. Ağırlıklar, bir sorunu çözmek için sinir ağı modeli tarafından kullanılan bilgileri temsil etmektedir. Sinir ağları, verilerin istatistiksel dağılımı hakkında herhangi bir varsayım olmaksızın, ağırlıkları doğrudan eğitim verilerinden değiştirmek için bir eğitim algoritması kullanır. Bu teknik, birçok etkileyici faktörün olduğu belirli bir süreçte veya karmaşık süreçlerde faydalıdır (Fausett, 1994; Rajamanickam, ve ark., 1997; Principe ve ark.; 1999; Almetwally, ve ark., 2014).

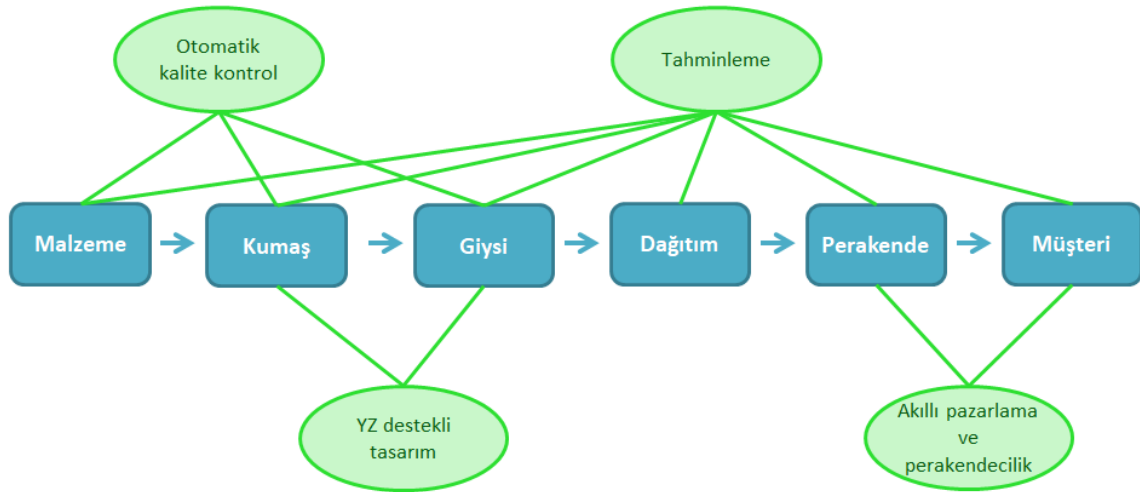
1.1. Yapay Zekanın Tekstilde Kullanılabileceği Alanlar

Tekstil sektöründeki teknolojik gelişmeler arasında bilgisayarlı ekipmanların kullanımı (özellikle tasarımda, kalıp yapımında ve kesimde), üç boyutlu (3D) tarama teknolojisi, giyilebilir teknolojinin entegrasyonu, gelişmiş malzeme taşıma sistemleri, otomasyon ve robotik veya yapay zeka kullanımı yer almaktadır. Son zamanlardaki önemli gelişme, malzemeleri tesis içinde taşımak veya üretim verimliliğini artırmaya yardımcı olarak üretimi kolaylaştırmak için robotik veya yapay zeka kullanımının artmasını içermektedir. Tüm bu gelişmelere rağmen, hazır giyim endüstrisi (özellikle de dikiş teknolojisi) diğer birçok imalat endüstrisine kıyasla önemli ölçüde daha az otomasyon içermektedir (Nayak ve Padhye, 2018).

Şekil 1.1, tipik bir tekstil lojistik zincirini göstermekte ve yapay zekanın olası katkıları için fırsatları vurgulamaktadır. *Kalite kontrol*, ürünün müşteri ile üzerinde anlaşılan özelliklere uygun olmasını sağlamayı amaçlayan süreçtir. İdeal olarak bu süreç, hataların maliyetini en aza indirmek için sorunları öngörmeyi ve önlemeyi amaçlamaktadır. Kumaş kontrolü, renk toleransı ve bitmiş ürün kontrolünde tekstil üretim zinciri boyunca uygulanabilmektedir. YZ, tekstil lojistik zincirinin farklı aşamalarında kalite kontrolünü otomatikleştirmek için teknikler sunmaktadır. Örneğin, görüntü işleme teknikleri ile kumaştaki hataları tespit etmek için bilgisayarlı görme teknikleri kullanılabilmektedir. Bir kamera vasıtasıyla, kumaş bir konveyör bandına sarılırken görüntüleri algılanmaktadır.

Diğer taraftan, bir YZ yazılımı hataları eş zamanlı olarak bulmak için görüntüleri analiz etmektedir. YZ bir çalışanın işini yapmaktadır, ancak daha hızlı ve hataya daha az eğilimlidir. Bu tür işlevleri sunan örnek sistemler arasında AIS (Birleşik Krallık), Cognex (ABD) ve WiseEye by PolyU (Hong Kong) bulunmaktadır. Renk toleransı için Datacolor (İsviçre), görüntü işleme ve makine öğrenimi kullanarak bu görevi otomatikleştiren bir şirket örneğidir (Chatbri ve ark., 2019).

YZ destekli tasarımda, tasarımcılar verimlilik ve yeniden kullanılabilirlik için bilgisayar destekli tasarım yazılımlarına (CAD) güvenmektedir. CAD'lerin sağladığı temel bilgilere ek olarak, tasarımcıların sanatsal dokunuşlarına ve deneyimlerine çok bağlıdır. Tasarımın ilk versiyonunu bitirdikten sonra, tasarımcıların herhangi bir fikri mülkiyeti ihlal etmediklerinden emin olmaları gerekmektedir. YZ daha iyi ve daha hızlı bir fikri mülkiyet kontrolü sağlayabilmektedir. İçerik tabanlı bir görüntü alma sistemi, tasarımcının girdisine görsel olarak benzeyen şablonları otomatik olarak bulmak için geniş bir tasarım modeli veri tabanını sorgulayabilmektedir. Tasarımcı daha sonra telif hakkı ihlalinden kaçınmak için tasarımlarını ayarlayabilmektedir (Chatbri ve ark., 2019).



Şekil 1.1. Tekstil lojistik zinciri (mavi diyagram) ve yapay zeka ile güçlendirme fırsatları (yeşil baloncuklar) (Chatbri ve ark., 2019)

Tahminleme, yeni durumlarla karşılaşıldığında geçmiş verilerden mantıklı tahminler yapmayı öğrenen yapay zeka tahmin modelleri ile elde edilmektedir. Tekstil ve konfeksiyon endüstrisinde tahminleme; kaynak planlamasında (örneğin hammaddeler, lojistik zinciri oluşturma, satışlar, personel alımı ve eğitimi), proses sürecini tahminlemede (ör. makine arızası tahmini), moda trendi tahminlemede ve piyasa gelişimini tahminlemede faydalı olmaktadır. YZ modelleriyle tahmin yapmak, şirketlerin piyasa dalgalanmalarına

ve süreç anormalliklerine hazır olmalarını sağlamaktadır, bu da daha sağlam ve daha güçlü rekabet avantajı anlamına gelmektedir. Fashion Pocket (Japonya), sosyal medyadaki milyonlarca görüntüden kıyafet çıkararak ve bu bilgiyi moda trendlerini tahmin etmek için kullanan bir sistem geliştirmiştir. Stylumia (Hindistan) benzer şekilde videolar, e-ticaret web siteleri ve sosyal medyadaki moda trendlerini tespit etmektedir. Zalando (Almanya), ürün tavsiyesi ve moda trendleri tahmini için müşteri çevrimiçi aramasını ve geçmiş deneyimlerini kullanmaktadır. Sosyal medya ve e-ticaret artık moda trendleri üzerinde önemli bir etkiye sahip olduğundan, bir sonraki trendleri belirlemek, hazır giyim şirketlerinin yakında modası geçecek ürünleri üretmekten kaçınarak maliyetlerini düşürmelerine yardımcı olmaktadır (Chatbri ve ark., 2019).

Perakende mümkün olduğu kadar çok ürün satmayı amaçlamaktadır ve pazarlama bunu başarmak için aracı olmaktadır. Burada veriler; ideal fiyatı belirleme, en çok satan zamanlar, reklam fikirleri, mağaza yönetimi gibi konularda pazarlama rehberliği sağlamaktadır. YZ, *akıllı pazarlama ve perakendecilikte* verileri kullanmak için teknikler sunmaktadır. Bu durum, şirketlere aşağıda sayılan önemli becerileri sağlamaktadır (Chatbri ve ark., 2019).

- Fiyat belirleme: YZ sistemi, rakipler tarafından benzer ürünlerin satış fiyatlarını tespit etmek ve buna göre rekabetçi bir fiyat noktası önermek için e-ticaret web sitelerini otomatik olarak tarayabilmektedir.

- Müşteri feedback (geri bildirim) analizi: Sosyal medyadan gelen veriler, herhangi bir zamanda belirli bir ürün veya genel olarak bir marka hakkındaki hissiyatı ortaya çıkarmak için analiz edilebilmektedir. Yapay zeka sistemleri ayrıca müşteri duyarlılığının arkasındaki nedenleri de araştırabilmektedir.

- Online perakendecilik geliştirme: YZ, online alışveriş deneyimini geliştirmek ve genç nesil müşteriler için daha çekici hale getirmek için teknolojiler sunmaktadır. Örneğin, Zalando (Almanya), kullanıcıların çektikleri sokak fotoğraflarını yüklemelerine izin verip, bir arama motoru vasıtasıyla fotoğraftakilere benzer ürünler bulmaktadır ve benzer şekilde Snap Fashion (İngiltere) da yapmaktadır. Levi's (ABD), müşterilerle bazı etkileşimleri otomatikleştirmek için sohbet robotlarını kullanmaktadır. Thread (İngiltere), müşterilerin moda stiline, konumuna, hava durumuna, geçmişteki alışveriş alışkanlıklarına ve benzer satın alma alışkanlıklarına sahip kullanıcıların eğilimlerine göre satın alacakları ürünler öneren kişisel stilist olarak kullanabilecekleri bir uygulama sağlamaktadır.

- Mağaza düzeni optimizasyonu: Bilgisayarla görme ve ses analizi, mağaza müşterilerini izlemek, hareketlerini ve davranışlarını analiz etmek için kullanılabilir. Bu bilgi, müşteri demografisi (örneğin gerçek zamanlı kişi sayımı, yaş aralıkları, cinsiyetleri, milliyetleri, giysileri ve moda stilleri) ve davranışları (örneğin yoğun saatler, mağaza içindeki sıcak bölgeler, satın alma tereddütünü algılama, gerçek zamanlı kuyruklar ve grup aktiviteleri) hakkında yararlı bilgiler sağlayabilmektedir. Mağaza yöneticileri, mağaza düzenini, ürün sunumunu ve personel planlamasını optimize etmek için bu verilerden yararlanabilmektedir.

1.2. Tez Çalışmasının Amacı ve Kapsamı

Şönül iplik üretiminde hammadde, hav ve bağ iplik numaraları, hav uzunlukları, hav yoğunluğu, büküm, uygulanan üretim hızı gibi nihai iplik özelliklerini etkileyecek parametreler bulunmaktadır. Bu özellikler şönül ipliğin mukavemetini ve hav stabilitesini (kohezyon mukavemetini) ve dolayısıyla şönül kumaşın mukavemetini ve aşınma direncini etkileyebilmektedir. Pek çok sanayi dalında, üretim öncesinde belirlenen parametrelerle üretim yapıldığında, üretim sonucunda ortaya çıkacak ürün özelliklerinin önceden bilinmesi büyük avantajlar sağlamaktadır. Belirli şönül iplik parametreleriyle şönül kumaş üretmeden önce, şönül kumaşın performans özelliklerini önceden bilmek, yani nihai ürünün özelliklerini tahmin eden bir sisteme sahip olmak aynı zamanda bir adım önde olmamızı da sağlayacaktır.

Bu tez çalışması ile şönül iplik ve şönül kumaş üretiminde etkili birtakım parametrelerin, şönül kumaşların bazı performans özelliklerine etkisinin üretim aşamasına geçmeden önce tahmin edilebilirliğinin araştırılması amaçlanmıştır. Malzeme olarak çeşitli kombinasyonlarla üretilen şönül ipliklerden elde edilen şönül kumaşlar; araştırılan performans özelliği olarak atkı-çözümlü yönünde kopma mukavemeti ile aşınma direnci ve kullanılacak yöntem olarak bir yapay zeka tekniği olan yapay sinir ağları seçilmiştir.

Tez çalışması dokuz bölümden oluşmaktadır. İlk bölümde tekstil sektörünün genel durumundan ve YZ'nin tekstilde kullanılabileceği alanlardan bahsedilmiştir. İkinci bölümde ise tekstilde YZ kullanımıyla ilgili çalışmalar literatürden örneklerle detaylandırılmıştır. Üçüncü bölümde tez çalışmasına yönelik literatür taraması yapılmıştır. Dört ve beşinci bölümde YZ çeşitlerinden olan ve tezde kullanılan YSA ve derin sinir ağları hakkında bilgi verilmiştir. Yedinci bölümde tezde kullanılan materyaller ve metotlar

alt başlıklarla anlatılmıştır. Sekizinci bölümde çalışmadan elde edilen bulgular ayrıntılı şekilde değerlendirilmiştir. Son bölümde ise çalışmanın genel bir değerlendirilmesi yapılmış ve öneriler sunulmuştur.



2. TEKSTİL SEKTÖRÜNDE YAPAY ZEKA UYGULAMALARI

YZ, lif sınıflandırma, iplik özelliklerinin tahmini, kumaş hata analizi ve boya reçetesi tahmini gibi çeşitli tekstil üretim süreçlerinde kullanılabilir. YZ, tekstil üretiminde ağırlıklı olarak aşağıdaki alanlarda yaygın olarak kullanılmaktadır (Nayak ve Padhye, 2018):

1. Mekanik özelliklerin tahmini
2. Sınıflandırma ve derecelendirme
3. Hataların tanımlanması ve analizi
4. Proses kontrolü ve çevrimiçi izleme
5. Tedarik zinciri yönetimi ve perakendecilik

YZ yöntemlerinin lif, iplik ve kumaş temel ürünlerindeki uygulamaları aşağıda yer alan konu başlıkları ile açıklanmıştır.

2.1. Lif ve İplik Üretiminde YZ Uygulanması

Tekstil lifleri, giyim ve diğer tekstillerin üretimi için temel hammaddedir. Birçok farklı tekstil lifi türü olduğu için, görsel inceleme ile bilinmeyen bir lifi tespit etmek genellikle zor olmaktadır. Geleneksel lif tanıma uygulamaları, yakma veya kimyasallar kullanılarak yapılan tahribatlı testlere dayanmaktadır. Son gelişmeler, optik mikroskop, Fourier Dönüşümlü Kızılötesi Spektroskopisi (FTIR) ve Raman Spektroskopisinin kullanımını içermektedir. YZ ayrıca tekstil liflerini renklerine ve incelik, uzunluk, üniformite oranı, mukavemet ve eğirme performansının iplik özellikleri üzerindeki etkisi gibi diğer özelliklerine göre tanımlamak ve sınıflandırmak için kullanılabilir (Nayak ve Padhye, 2018).

İplik üretiminin çeşitli yöntemleri arasında ring iplik eğirme, çeşitli iplik üretimine uygun olmakla birlikte üretilen iplikler dayanıklı olmaktadır. Bilezik boyutu, kopça tipi, eğirme hızı gibi operasyonel parametreler eğirme performansını ve iplik özelliklerini (lineer yoğunluk, büküm miktarı ve yönü, iplik mukavemeti ve üniformite) etkilemektedir. İplik üretimi sırasında birkaç bağımsız değişken söz konusu olduğundan, YZ uygulamasının tüm parametre aralığını kapsaması oldukça zordur. Her bağımsız değişkenin etkileşimli katkısının değerlendirilmesi, deneysel gözlemlerin veya fabrika ölçümlerinin ara değerini hesaplamak ve tahmin etmek de zordur. İplik üretiminde, lif özelliklerinden ipliğin sanal olarak modellenmesi, iplik çekme özelliklerinin tahmini, iplik düzgünsüzlüğünün tahmini

ve iplik mühendisliği gibi çeşitli YZ uygulamaları bulunmaktadır (Nayak ve Padhye, 2018).

Liang ve ark. (2012), objektif bir iplik sınıflandırma sistemi tanıtmışlardır. İplik görüntüleri elde etmek için görüntü işleme kullanmışlardır. İplik hatalarını ve tüylülüğü özelliklerini bu görüntülerden çıkarmak için belirginlik haritası, dalgacık analizi ve istatistiksel ölçüm kullanılmış ve elde edilen özellikler kullanılarak bulanık sinir ağı eğitilmiştir. 576 iplik görüntüsünden oluşan bir veri tabanındaki deneysel sonuçlar, önerilen akıllı değerlendirme sisteminin hem bireysel iplik kategorisi (%90 üzeri) hem de global iplik veri tabanı (%87.3) için iyi tahminleme sonuçları vermiştir. Sengupta ve ark. (2015), renkli pamuk ve jüt ipliklerinde iplik çapını, hatalarını ve tüylülüğü tespit etmek için ucuz bir görüntü işleme sistemi tasarlamışlardır. Li ve ark. (2018), iplik yüzeyi sınıflandırması için iki ölçekli bir dikkat sistemi ve olasılıksal sinir ağlarından yararlanmıştır. Sekiz dereceli ve beş dereceli sınıflandırmalara dayalı olarak iplikler değerlendirilmiştir. Sırasıyla %92.23 ve %93.58 doğrulukla sınıflandırma yapabildiği gözlemlenmiştir. El-Geiheini ve ark. (2020), görüntü işleme ve yapay sinir ağlarından yararlanılarak, farklı iplik türleri için iplik mukavemeti ve uzama yüzdesinin tahmini için maliyet ve zaman açısından uygun bir yöntem kullanılarak model geliştirmişlerdir. Numune görüntüler yakalanıp önceden işlenip ve vektörler tanımlanıp ağ girdileri olarak kullanılmıştır. Geri yayılma kuralıyla eğitilmiş ileri beslemeli sinir ağları kullanılmıştır. Pamuk ipliği modeli için eğitim hataları, iplik mukavemeti ve uzama yüzdesi için sırasıyla 0,120 ve 0,074 olarak elde edilmiştir. Karışıklı iplik modeli için eğitim hataları, ipliğin uzama yüzdesi ve mukavemeti için sırasıyla 0,090 ve 0,113 olarak elde edilmiştir.

Bu konuda çalışmalar devam etmektedir, ancak bazı durumlar dikkate alınmalıdır. Örneğin, iki farklı iplik fabrikası, belirli standartlara göre belirli bir iplik numarası üretmek için aynı lifi kullanabilmektedir. Ancak ipliklerin eğirme performansı genellikle bir fabrikadan diğerine değişmektedir. Bu nedenle, farklı fabrikalarda mevcut olan tüm bilinen proses değişkenlerini ele almak için deneysel modellerin geliştirilmesi gerekmektedir. Ayrıca, iplik kalitesinin doğru bir şekilde tahmin edilmesi için bu bilgiyi her bir fabrikada bireysel olarak genelleştirmek de gereklidir (Nayak ve Padhye, 2018).

2.2. Kumaş Üretiminde YZ Uygulanması

Bir giyim endüstrisinin ana hammaddesi kumaştır. Kumaşın kalitesi giysinin kalitesini, verimliliği ve giysilerin üretilme kolaylığını etkilemektedir. Kumaşlar, giysinin tipine ve son kullanım uygulamalarına göre seçilmektedir. Herhangi bir giysiyi üretmek için kumaş özellikleri birincil ve ikincil olarak sınıflandırılabilir. Fiziksel boyutlar birincil olarak kabul edilirken, kumaşın dış kuvvetlere tepkisi ikincil olarak kabul edilmektedir. Tüketici açısından giysi görünümü, konfor ve dayanıklılık önemli parametrelerdir. Bu parametreleri kontrol etmek ve belirli kumaş özelliklerini elde etmek için YZ uygulanabilmektedir (Nayak ve Padhye, 2018).

2.2.1. Kumaş özelliklerini tahmin etme

Günümüzün rekabetçi pazarında, giysi üreticileri ürün geliştirme sürecini etkileyen teslim süresini azaltmaya çalışmaktadır. Kumaş üreticileri, üretim sırasında kalite gereksinimlerini karşılamak ve kumaşı zamanında teslim etmek için çok çalışmak zorundadır. Bu nedenle, modern hesaplama ve simülasyon araçlarının kullanımı, kumaş davranışını tahmin etme süresini azaltmaya yardımcı olabilmektedir. Örneğin YZ, lif, iplik ve kumaş yapısal verilerini kullanarak nöro-bulanık veya diğer yaklaşımların yardımıyla üretim öncesi kumaş özelliklerini tahmin etmek için kullanılabilir. YZ uygularken, lif ve iplik parametreleri arasında uygun bir doğrusal ve doğrusal olmayan ilişki kurmak esastır ve kumaşın özelliğinin tahmin edilmesi gerekmektedir. Bununla birlikte, YZ uygulanması, kumaş üreticileri için çok pahalı olabilmekte ve bu da üretim maliyetini artırabilmektedir (Nayak ve Padhye, 2018).

Yapay zeka uygulamasıyla kumaş performans özelliklerini, konforunu ve dayanıklılığını tahmin etmek için çeşitli araştırmalar yapılmıştır. Örneğin, Behera ve Mishra (2007), kamgarn takım elbise kumaşlarının estetik ve fonksiyonel özelliklerini tahmin etmek için Yapay Sinir Ağı (YSA) kullanmıştır. YSA, elyaf özelliklerinden ve kumaş yapısal özelliklerinden kumaş özelliklerini doğru bir şekilde tahmin edebilmiştir. Öngörülen sonuçlar ile deneysel veriler arasında iyi bir korelasyon bulunmuştur. Beltran ve ark. (2005), YSA kullanarak ve lif, iplik ile kumaş özellikleri arasındaki ilişkileri kurarak kumaş boncuklanma eğilimini araştırmıştır. Bu model, boncuklanma performansını tahmin etmek için saf yün örme kumaşlar için kullanılmıştır. Benzer şekilde Ünal ve ark. (2012) süprem kumaşın özelliklerini tahmin etmek için regresyon analizi ve YSA modellerini kullanmıştır.

Tüketicilerin giysinin duyusal ve termofizyolojik konfor özelliklerine ilgisi artmaktadır. Dünya çapında çeşitli araştırma kuruluşları, kumaş hissi (duyusal konfor) ve giyim esnasında vücuttan ısı ve ter taşınması (termofizyolojik konfor) ile ilgili giysi konfor özelliklerinin araştırılması ve geliştirilmesi ile ilgilenmektedir. Kumaşın duyusal özelliklerini tahmin etmek için Kawabata değerlendirme sistemi (KES) gibi uygun ekipmanların kullanılmasıyla hem konfor yönleri (duyusal ve termofizyolojik) laboratuvarda araştırılabilmekte hem de bir dizi ekipman kumaş hava geçirgenliği, termal direnç, su buharı direnci ve nem yönetimi özellikleri tahmin edilebilmektedir.

Yukarıda listelenen ekipmanlara ek olarak, konfor özelliklerini araştırmak için YZ da uygulanabilmektedir. Duyusal konfor düşünüldüğünde, YZ uygulaması ile kumaşlar tuşe değerlerine göre sınıflandırılabilmektedir (Park ve ark., 2000; Wong ve ark., 2003; Hui ve ark., 2004). Genel olarak, tuşe değerinin tahmini, kumaşa dokunduktan sonra uzmanların görüşüne göre özneldir. Bununla birlikte, yapay zeka kullanarak kumaş tuşesini tahmin etmek için çeşitli araştırmalar yapılmıştır. Sonuçlar, mevsime veya giysi türüne göre doğru kumaş türünü seçmek için kullanılabilir. Kumaş özelliklerinden tuşe tahmini için bir YSA geliştirirken, kumaş özellikleri ile tuşe özellikleri arasında bir ilişki kurmak esas olmaktadır (Hui ve ark., 2004).

Kumaş termofizyolojik konfor özelliklerini tahmin etmede yapay zekanın geniş bir uygulama alanı bulunmaktadır (Luo ve ark., 2007; Wang ve ark., 2005). Örneğin, Wang ve ark. (2005), kumaşın termal konfor özelliklerini tahmin etmek için bulanık mantık (BM) tabanlı bir sistem geliştirmiştir. Termal konforun öznel algıları, giysiyi giyerken termal ve nem hissiyatlarının simüle edilmiş sonuçlarına dayandırılmıştır. İnsan derisi ve giysiler arasındaki ısı ve nem değişimini simüle etmek için bir dizi matematiksel modelden oluşan bir modelleme sistemi kullanılmıştır. Bu çalışmada insan vücudunun termoregülatuar sistemi ve nöropsikolojik tepkileri dikkate alınmıştır.

Luo ve ark. (2007), fonksiyonel tekstil sistemleri tasarlarırken giysi termal konforunu tahmin etmek için bir bulanık sinir ağı (BSA) önermiştir. Bu model, insan vücudunun iç ve cilt sıcaklıklarına dayanıyordu. BSA'yı geliştirmek için ileri beslemeli geri yayılım (GY) ağı kullanılmıştır. BSA kullanımı, eğitim verilerinin miktarını azaltmaya yardımcı olmuştur. Ayrıca, alan uzmanının bilgisini edinmek, sunmak ve kullanmak için BSA, insan-makine dostu bir bilgi temsil şemasının elde edilmesine yardımcı olmuştur. Deneysel sonuçlar ile BSA tarafından tahmin edilen sonuçlar arasında iyi bir korelasyon

kurulmuştur. YSA sistemleri ayrıca kumaşların termal direncini tahmin etmek için kullanılmıştır (Bhattacharjee ve Kothari, 2007; Alibi ve ark., 2012).

Yapay zeka, kumaş özelliklerine dayalı olarak kumaşın son kullanım uygulamalarını tahmin etmek için kullanılabilir. Örneğin, Chen ve ark. (2001), uzama, kesme, eğilme, sıkıştırma, yüzey sürtünmesi ve yüzey pürüzlülüğü gibi düşük gerilimdeki özelliklerinden kumaşların son kullanımını tahmin etmek için bir YSA kullanmıştır. Bu parametreler KES aletleri kullanılarak ölçülmüştür. Kumaşın son kullanım uygulaması, tahmin sırasında 0,07 hata oranıyla YSA ile belirlenmiştir.

Kothari ve Bhattacharjee (2011), YSA'ları ve bunların yapısını, geliştirilmesini ve dokuma kumaş termal özelliklerine uygulanmasını araştırmıştır. İleri beslemeli GY sinir ağı, girdi olarak dokuma, iplik numarası, iplik yoğunluğu, ağırlık ve kalınlık gibi kumaş yapı parametrelerine dayalı olarak kumaşların ısı yalıtımını tahmin edebilmiştir. Burada tasarlanan ileri beslemeli GY sinir ağı, kumaşın ısı yalıtımını 0,96 determinasyon katsayısıyla doğru bir şekilde tahmin edebilmiştir. Xiao ve ark. (2020), GY sinir ağı modelini kullanan akıllı boncuklanma tahmin modeli ve genetik algoritma ile optimize edilmiş bir model sunmuşlardır. GA, GY sinir ağının başlangıç ağırlığı ve eşiği dikkate alınarak önerilmiştir ve polyester-pamuk karışımı dokuma kumaşların tüylenme tahmini için eğitim hızını ve doğruluğunu daha da geliştirmiştir. Sonuçlar, GA ile optimize edilmiş modelin maksimum eğitim adımı sayısının, GY modeline kıyasla 164 adımdan 137 adıma düştüğünü göstermiştir. GA ile optimize edilen modelin eğitim uygunluğu 0,914'ten 0,945'e; simülasyon uygunluğu 0,912'den 0,987'ye çıkarılmıştır ve kök ortalama kare hatası 1,0431'den 0,6842'ye düşmüştür. Genetik algoritmayla optimize edilen model, deneysel ve tahmin edilen değerler arasında daha iyi bir uyum göstermiştir. Youn ve ark. (2024), YZ tabanlı tekstil dijitalleştirme doğruluğunu bir dökümlülük test yöntemi kullanarak değerlendirmeyi amaçlamışlardır. Dökümlülük katsayısı analizi, fiziksel özellik tabanlı simüle edilmiş dökümlülük katsayısının %2 ila %11 arasında değişen normalleştirilmiş bir ortalama mutlak hata sergilediğini, YZ tabanlı simüle edilmiş dökümlülük katsayısının ise %3 ila 51 aralığında bir hata gösterdiğini ortaya çıkarmıştır. Özellikle, çok gevşek veya çok sert kumaş numuneleri dışındaki numuneler için, YZ tabanlı simülasyon %3-15 arasında bir hata sergilemiştir.

2.2.2. Renk çözeltileri

Renk, tasarımda tüketicilerin yanıt verdiği ilk unsurdur ve bu nedenle tekstillerin önemli özelliklerinden biridir. Tüketiciler, renk çekiciliğine göre giysi veya diğer moda aksesuarlarını seçer veya reddeder. Bu nedenle, doğru rengi elde etmek için boyama ve baskı sırasında hassas kalite kontrolü önemlidir ve bu da satış hacmini etkileyebilmektedir. Hem boyama hem de baskı işlemi, gerekli renk haslığı, gölge derinliği, renk uyumu ve yüzey özelliklerinin elde edilmesini sağlamalıdır. Bu parametreler, boya ve kumaş kombinasyonlarından ve bunları yöneten kimyasal kurallardan etkilenmektedir. Bu parametrelerin izin verilen sınırdan sapması, tüm kumaş partisinin yeniden işlem görmesine veya reddedilmesine yol açabilmektedir (Nayak ve Padhye, 2018).

YZ kullanımı, şu konularda çözüm olabilmektedir; reçete tahmini; boyama ve baskı sırasında proses kontrolü; renk uyumu ve nihai boyalı veya baskılı kumaşın değerlendirilmesi. Bu süreç, bir dizi girdi (renk değerleri) ve çıktı (her boyanın konsantrasyonları) verileri ile YSA'nın eğitimini içermektedir. YSA, eğitildikten sonra, herhangi bir bilinmeyen renkli numune setinde konsantrasyonları hesaplamak için kullanılabilir (Nayak ve Padhye, 2018).

Yapay zekanın renk çözümüne yönelik uygulamalarından biri, fitil ipliğe dönüştürülürken elyaf karıştırma aşamasındadır. Fitil ipliğe dönüştürülür ve ardından iplik dokuma veya örme ile kumaşa dönüştürülür. Bu aşamada kullanılan herhangi bir kimyasal bileşik olmadığı için renk efekti herhangi bir kimyasal kuraldan etkilenmez. Bununla birlikte, farklı türde liflerin karıştırılmasındaki yakınlık, rengi daha çok fiziksel olarak yönetir. Bu nedenle renk üretimi, liflerin doğasına ve karışımın uyumluluğuna bağlıdır. YZ kullanımı, farklı renkteki lifler birbirine karıştırıldığında üretilen rengin tahmin edilmesine yardımcı olabilmektedir. Homojen bir karışım durumunda, teorik ve ampirik modeller kullanılarak renk tahmini daha doğru bir şekilde gerçekleştirilebilmektedir (Nayak ve Padhye, 2018).


Boyama bittikten sonra kumaşta istenilen renk derinliğinin elde edilmesi çok önemlidir. İyi bir boyalı kumaş elde etmek için doğru reçete ve boyama sırasında doğru zamanlama şarttır. Boyalı mal ile kontrol arasındaki ton farkı tolerans sınırını aştığında, partinin tamamı ya yeniden işlenir ya da reddedilir. Boyama süresini tahmin etmek için çoklu regresyon analizi gibi istatistiksel araçlar kullanılabilir. Ancak YSA uygulamasının çoklu regresyon analizinden daha doğru olduğu bulunmuştur (Senthilkumar ve Selvakumar, 2006; Jasper ve ark., 1993).

Zhang ve Yang (2014), GA tarafından optimize edilen destek vektör makinesini kullanarak boyalı kumaşların renk kalitesini tahmin etmeye çalışmışlardır. Deneysel sonuçlar, geleneksel Naive Bayesian algoritmasıyla karşılaştırıldığında, önerilen değerlendirme algoritmaları ve modelinin, boyalı kumaşların renk kalitesini hızlı ve kararlı bir şekilde değerlendirebildiğini, tahmin doğruluğunun %9 arttığını ve bağıl hatanın 0,0985 azaldığını göstermiştir. Jing ve ark. (2016), optimize edilmiş Gabor filtresini bulmak için renkli hatasız kumaş görüntüsü ve GA kullanmıştır. Ardından hatalı parçaları otomatik olarak bulmak için bu Gabor filtresini hatalı kumaş görüntülerine uygulamıştır (%95'ten fazla başarıya ulaşıldığı rapor edilmiştir). Vadood ve Haji (2022), kök boyayla boyanmış polyester kumaşın renk koordinatlarını tahmin eden hibrit yapay zeka modeli geliştirmişlerdir. Bu şekilde en iyi boyama parametrelerini bulmayı amaçlamışlardır. Boyama parametreleri ile l^* , a^* ve b^* olarak bilinen renk koordinat değerleri arasındaki ilişkiler istatistiksel olarak analiz edilmiştir. Daha sonra her renk koordinatı, eski tipik yöntem olan doğrusal regresyon ve YSA kullanılarak boyama parametrelerine göre ayrı ayrı modellenmiştir. l^* , a^* , b^* değerleri için, YSA modellerinin sırasıyla 0.67, 1.29, 1.27 ve doğrusal regresyon modellerinin sırasıyla 3.09, 6.20, 11.17 ortalama mutlak yüzdesel hataya sahip olduğu görülmüştür.

2.2.3. Kumaş hatası tespiti

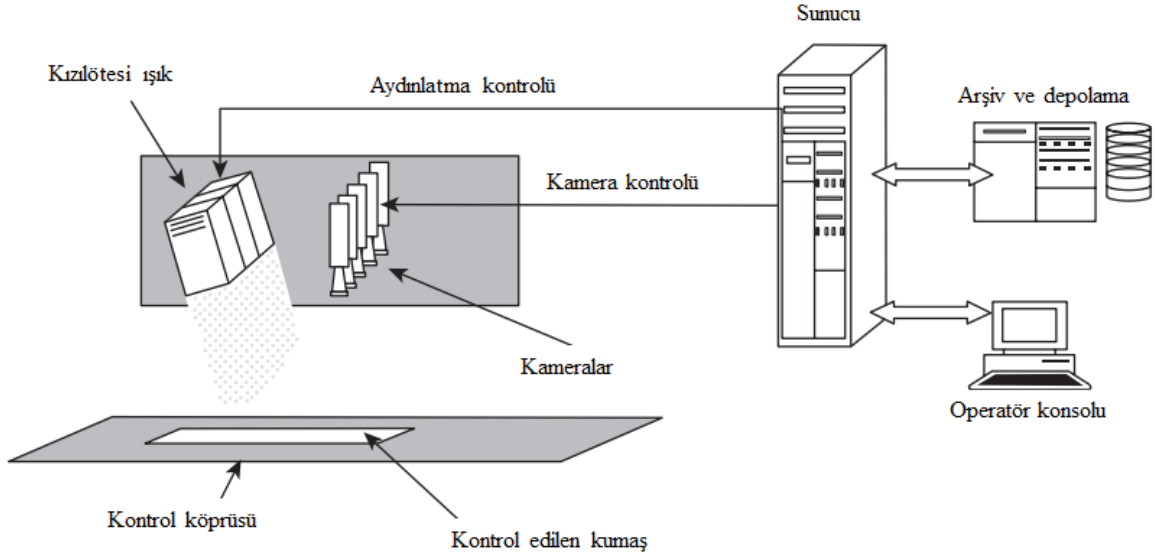
Düşük kalitede bir kumaş, standart altı giysilerle sonuçlanabileceği gibi, giysi üretimi sırasında üretkenliği de azaltabilmektedir. Kumaştaki herhangi bir hata nihai giysiye aktarılmakta ve bu da giysinin reddedilmesine neden olabilmektedir. Bu nedenle, giysiyi üretmeden önce kumaşın kalitesini kontrol etmek önemlidir. Genel olarak kumaş muayenesi, ışıklı masalar veya ekipman kullanılarak vasıflı işçiler tarafından gerçekleştirilmektedir. Bu süreç oldukça yavaştır ve birçok kez hataların giysiye geçmesine izin verebilmektedir. Ayrıca, kumaş denetçilerinin verimliliği yorgunlukla birlikte hızla düşmektedir. Bununla birlikte, YZ kullanımı bu görevi daha hızlı, çok daha yüksek doğrulukla ve yorulmadan gerçekleştirebilmektedir (Nayak ve Padhye, 2018).

YZ, hazır giyim endüstrisinde alınan kumaşların hata denetimi ve derecelendirilmesi için uygulanabilmektedir. Hataların görüntüsü sistemde saklanır ve yakalanan görüntü ile karşılaştırılmaktadır (Şekil 2.1). Bir fark gözlenirse, hata tanımlanır ve kontrolcü hata noktalarını hesaplar.



Şekil 2.1. Yapay zeka ile incelenen farklı kumaş hataları (a) atık lif, (b) çözgü yüzmesi, (c) geri çekme, (d) delik, (e) sökük ve (f) kapalı makine örme hatası (Ngan ve ark., 2011)

Ayrıca, kumaş üretimi sırasında önceden eğitilmiş bir YSA, Şekil 2.2'de gösterildiği gibi yükten bağımsız aygıt kameraları ile dokuma tezgahı veya örgü makinesindeki kumaş hatalarını algılamak ve işaretlemek için kullanılabilir. Bu aygıt, bir proses kontrol aracı olarak kullanılabilir, sonraki aşamalarda kumaş kontrolünün zaman ve maliyetinden tasarruf sağlamaktadır. Yapay zeka uygulamasıyla kumaşların sınıflandırılması, hataların sıklığı ve önemiyeti temelinde yapılabilir. Kumaş kalitesi elyaf tipine, iplik özelliklerine ve kumaş yapısına bağlıdır. Farklı giysi türleri için kumaş kalitesi gereksinimleri farklıdır. YZ, giysinin son kullanım uygulamasına bağlı olarak uygun kumaş seçimi için kullanılabilir.



Şekil 2.2. Tipik bir otomatik kontrol sisteminin konfigürasyonu (Abouelela ve ark., 2005)

Yapay zekanın kumaş hatası denetlemedeki çeşitli uygulamaları, kumaş hatalarını tanımak için GY algoritmasına dayalı YSA'nın uygulanması (Tsai ve Hu, 1996); görüntü analizine ve YSA'ya dayalı örme kumaş hatalarının tespiti ve sınıflandırılması (Shady ve ark., 2006); iki tür optik kullanılarak yapılan, YSA ile hataların tespiti ve sınıflandırılması (Tilocca ve ark., 2002); ileri beslemeli bir YSA kullanarak kumaş hatalarının tespiti (Kumar, 2003); dokuma ve örme kumaşların BM ve GY öğrenme algoritmasına dayalı YSA'ya göre sınıflandırılması (Huang ve Chen, 2001); desenli kumaş üzerindeki hataları tespit etmek için dalgacık dönüşümünü kullanarak otomatik bir görsel inceleme yöntemi geliştirmek (Ngan ve ark., 2005); ve YSA ile eğitilmiş yapılandırma elemanları tarafından dokuma kumaşlardaki hataların tespitini (Chandra ve ark., 2010) içermektedir.

Son dönemlerde de kumaşla ilgili çalışmalarda YZ kullanımı görülmektedir. Çelik ve ark. (2015), farklı tipteki kumaş muayene makinelerine uyarlanabilecek bir yapay görme sistemi önermişlerdir. Denim kumaşın görüntü çerçeveleri bir çizgi tarama kamerası kullanılarak elde edilmiştir. Gabor filtresi ve çift eşikleme yöntemleri kullanılarak bir algoritma geliştirilmiştir. Algoritmanın performansı altı tür hata (delik, çözü eksikliği, atkı eksikliği, kirli iplik, su lekesi ve iplik akışı (düğüm)) içeren bir denim kumaş örneğinin analiz edilmesiyle gerçek zamanlı olarak test edilmiştir. Denim kumaş numunelerinin tüm hatalı alanları %99,6 genel tespit oranıyla başarıyla tespit edilmiştir. Das ve ark. (2021), dokuma kumaştaki hataları otomatik olarak tanımlamak için derin öğrenme kullanmışlardır. Çalışmanın sonucunda delikler için %78,1, lekeler için %81,6, kenar hataları için %84,7 ve kıvrımlar için %74,6 sınıflandırma doğruluğu elde edilmiştir. Bu

araştırma ile, giysi inceleme sistemlerinde otomatik hata tespit ve tanımlama sistemlerinin kullanılmasının giysinin üretimini ve kalitesini artıracak sonucuna varılmıştır. Çelik ve ark. (2022) tarafından yapılan çalışma, kumaş hatalarının otomatik olarak kontrol edilebildiğini ve tespit edilen hataların sınıflandırılabilirdiğini, yuvarlak örme makinelerine uyarlamak için geliştirilmiş bir yapay görme sistemi sunmaktadır. Örme kumaş yüzeyi, gerçek zamanlı olarak imalat sırasında algılanmıştır. Sınıflandırma işlemi için üç farklı transfer öğrenme mimarisi (ResNet-50, AlexNet, GoogLeNet) uygulanmıştır. Beş yaygın örme kumaş hatası, yapay zeka tabanlı yazılımla tespit edilmiş ve ResNet-50 mimarisi kullanılarak ortalama %98 başarı oranıyla sınıflandırılmıştır. Öztaş ve ark. (2024), görsel olarak tespit edilmesi mümkün olmayan hasarları, tespit etmeye çalışmışlardır. Bu amaçla cam ve karbon takviyeli epoksi kompozit malzemeleri kullanmışlardır. Yapay olarak hasar görmüş numuneler ve hasarsız numuneler görüntü işleme algoritmaları ile hasar analizinde kullanılmıştır. Geliştirilen görüntü işleme algoritmaları ile hasarların yönelimi, sınırları ve alan hesaplamaları başarıyla yapılmıştır. Çalışmada kullanılan Ayrık Dalgacık Dönüşümü yönteminin etkinliği ön plana çıkmıştır.

2.3. Giysi İmalatında YZ Uygulanması

Giysi üretim süreci, tüketicilerin artan talebini karşılamak, hata sayısını azaltmak ve üretim maliyetini düşük tutmak için daha otomatik hale gelmektedir. YZ, giysi tasarımına göre dikilmiş bir dikişin performansını; üretim planlama ve kontrolde, çeşitli dikiş işlemlerinde ve kalite kontrolde tahmin etmek için giderek daha fazla kullanılmaktadır. YZ, belirli bir işlemde sonra giysi özelliklerini tahmin etmek için giysinin akıllı üretimi için uygulanabilmektedir. Bu nedenle, kumaş mühendisliği ile uygun giysi tasarımı ve giysi üretim süreçlerinin izlenmesi için kullanılabilirlik.

2.3.1. Dikiş performansı

Dikilmiş giysilerde, iki veya daha fazla kumaş parçasını birleştirmek için dikişler ve ilmekler kullanılmaktadır. Dikiş oluşturma kolaylığı ve dikiş performansı, "dikilebilirlik" olarak bilinen terime göre değerlendirilen önemli parametrelerdir. Kumaşın çekme, kesme, bükme ve yüzey gibi düşük gerilimli mekanik özellikleri dikilebilirliği etkileyebilmektedir. YZ sistemi, giysi üretimi sırasında farklı kumaşların dikilebilirliğini bulmak için kullanılabilirlik (Nayak ve ark., 2010.). Kumaşın mekanik özellikleri serim, kesim ve dikim sırasındaki performansı etkilemektedir. Örneğin, Chen ve ark. (2001), giysi üretimi

sırasındaki performanslarını değerlendirmek için kumaş mekanik özelliklerini girdi parametresi olarak kullanmıştır.

Kaliteli bir giysi için kaliteli bir dikiş şarttır. Dikiş kalitesindeki farklılıklar, dikiş makinesinin yanlış ayarlanmasından veya insan hatasından kaynaklanabilmektedir. Dikiş işlemine başlamadan önce kumaş özelliklerine ve dikiş tipine bağlı olarak dikiş makinesi parametrelerinin optimize edilmesi gerekmektedir. Esneme, bozulma, iğne kesme indeksi ve diğer mekanik özellikler gibi kumaş parametreleri, optimizasyondan önce tespit edilmesi gereken dikiş verimliliğini yönetmektedir. Benzer şekilde, dikiş hatalarından arınmış kaliteli bir giysi üretmek için yetenekli bir operatör gerekmektedir (Nayak ve Padhye, 2018).

Dikiş performansı, kumaş tipi, dikiş ipliği kombinasyonu, dikiş tipi, iğne boyutu, dikiş yoğunluğu ve dikiş makinesi durumunu gibi dikiş koşullarına bağlıdır. Dikiş performans özellikleri, YZ tarafından tahmin edilebilen dikiş büzülmesi, dikiş kayması ve iplik kopması ile değerlendirilebilmektedir. Kumaş alan yoğunluğu, kalınlığı, çözgü ve atkı yönünde bükülme sertliği girdi olarak alınarak GY algoritması kullanılarak dikiş büzülmesi tespit edilebilmektedir. Dikiş performansı özellikleri, ağı yeterli sayıda tekrarlanan deneysel veri ile eğiterek kumaş üretim parametrelerinden doğru bir şekilde tahmin edilebilmektedir (Nayak ve Padhye, 2018).

Hui ve ark. (2007) ve Hui ve Ng (2009), dikiş büzülmesi, dikiş yüzmesi ve dikiş verimliliğine dayalı olarak giysi imalatı sırasında kumaşların performansını araştırmak için YSA'yı uygulamışlardır. YSA modeli, az miktarda eğitim veri seti kullanılmasına rağmen, yapı hatalarını tespit etmede yüksek doğruluk vermiştir. Dikiş performansının tahmin edilmesiyle ilgili diğer birkaç araştırma şunları içermektedir: tekstil dikişlerinin otomatik kalite kontrolü için YSA uygulaması (Bahlmann ve ark., 1999); dikiş sırasında kumaşların performansını tahmin etmek için YSA uygulaması (Hui ve Ng, 2005); ve kumaşların dikiş mukavemeti ve kopma uzamasının modellenmesi için YSA uygulaması (Yıldız ve ark., 2013). Konuyla ilgili olarak son yıllarda yapılan diğer bazı çalışmalar aşağıda verilmiştir.

Midha ve ark. (2010), yüksek hızlı endüstriyel dikiş sırasında dikiş ipliği mukavemet kaybını tespit etmek için YSA kullanmışlardır. Giriş parametreleri olarak iplik doğrusal yoğunluğu, kumaş alanı yoğunluğu, kumaş katmanlarının sayısı, dikiş yoğunluğu ve iğne boyutu alınmıştır. 54 numune eğitim için ve 14 numune test için olmak üzere toplamda 68 numune kullanılmıştır. Elde edilen veriler iplik tiplerine göre dört gruba bölünüp eğitim

yapılmıştır. Test setinde ortalama karesel hatası, dört grupta 17,63 ila 20,56 arasında değerler almıştır. Dört gruptaki determinasyon katsayısı sırasıyla 0,94, 0,83, 0,83 ve 0,85 olarak bulunmuştur. Brad ve ark. (2015), dikiş büzülmesi için Fourier dönüşümünü ve denetimsiz bir sinir ağı olan Kohonen Haritasını kullanarak spektral görüntü analizi yapmışlardır. Girdi görüntüleri, 5. sınıftan (en iyi) 1. sınıfa (en kötü) kadar beş ayrı kalite derecesine göre sınıflandırılmıştır. Kurulan modele bir dikiş büzülme görüntüsü verildiğinde ait olduğu beş sınıftan birine atanacaktır. Kohonen ağı ile büzülme hataları %71,42 oranında doğru bir şekilde sınıflandırılmıştır. Pan ve ark. (2017), otomatik dikiş büzülmesi değerlendirmesi için iki boyutlu görüntü analiz sistemi geliştirmişlerdir. Analiz için en uygun görüntü boyutlarını belirlemek amacıyla çeşitli genişlik ve uzunluklardaki dikiş büzülme görüntüleri üzerinde manuel değerlendirmelerdeki hataları analiz edilmiş ve dikiş hattını bulmak için kenar algılama ve Hough dönüşümü teknikleri kullanılmıştır. Dikiş büzülmesinin beş karakteristik özelliği, beyazlatılmış profil üzerinde farklı eşikler kullanılarak ölçülmüş ve kumaş dikiş büzme derecesinin otomatik sınıflandırmasını gerçekleştirmek için GY sinir ağı oluşturulmuştur. Deneysel sonuçlar, modelin 25 numuneden 23 tanesini doğru sınıflandırabildiğini göstermiştir. Sarkar ve ark. (2021), denim giysilerin dikiş mukavemetine yönelik bir tahmin modeli geliştirmek için bulanık mantık uzman sistemi kullanmıştır. Bulanık uzman sistemi, denim giysilerin üst üste bindirilmiş dikişlerinde uygun dikiş mukavemetini ayarlamak için bir karar verme aracı sağlamak üzere geliştirilmiştir. Sistem dört ana bileşenden oluşturulmuştur: bulanıklaştırma arayüzü, kural tabanları, karar verme mantığı ve durulaştırma arayüzü. Bulanık mantık sisteminin inşasında giriş parametresi olarak iplik doğrusal yoğunluğu ve inçteki dikiş sayısı olmak üzere iki değişken, çıkış parametresi olarak ise dikiş mukavemeti kullanılmıştır. Hem deneysel hem de tahmin edilen sonuçlar karşılaştırılmıştır. Determinasyon katsayısının 0,98 değerini vermesi, denim giysilerin dikiş mukavemetini yüksek düzeyde tahmin edebildiğini göstermiştir.

2.3.2. Bilgisayar destekli tasarım sistemleri

Giysi imalatındaki önemli adımlardan biri, kağıt kalıpların tasarımcılar tarafından yapıldığı ve daha sonra bir bilgisayara sayısallaştırıldığı kalıp yapımıdır. Bir giysi için, üç boyutlu giysinin temel blokları olan iki boyutlu kalıplar hazırlanır. Hazır giyim endüstrisinde model oluşturma, sayısallaştırma, serilendirme ve pastal planlama için çeşitli CAD yazılımları kullanılmaktadır. CAD yazılımı, yüksek verimlilik ve iyileştirilmiş kalite elde etmeye yardımcı olmaktadır. Giyim tasarımında yer alan tasarımcılar, CAD yazılımını

kullanarak çok sayıda tasarım oluşturmaktadır. Bununla birlikte, CAD yazılımı, belirli bir giysi stili için giysi kalıplarını veya tasarımlarını otomatik olarak oluşturmak için kullanılamamaktadır. Ek olarak, birçok hazır giyim endüstrisinde geleneksel giysi kalıbı oluşturma yöntemi hala deneyimli tasarımcılar tarafından yapılmaktadır ve kalıp oluşturma yapay zeka kullanımının kapsamı olmasına rağmen CAD kullanımını içermemektedir (Nayak ve Padhye, 2018).

Temel giyim kalıplarını otomatik olarak geliştirmeye yardımcı olabilecek yapay zekayı uygulamak için çeşitli araştırmalar yapılmıştır. Örneğin, Inui (1996), sistem kullanıcılarının tercih ettiği giyim tasarımlarını aramak için kullanılabilir bir YZ entegreli CAD sistemi (CAD ve GA kombinasyonu) geliştirmiştir. Arama süreci, kullanıcının sistemler tarafından üretilen örnekleri değerlendirdiği insan-makine etkileşim döngülerini içermektedir. Kim ve Cho (2000) tarafından kadın elbise tasarımı için etkileşimli GA tabanlı bir moda tasarım destek sistemi geliştirilmiştir. Bu sistem, insan tercihlerini ve duygularını kullanarak en uygun moda tasarımını tahmin edebilmektedir. Sistem arayüzünü geliştirmek için Sanal Gerçeklik Modelleme Dili (3D Studio MAX) ve OpenGL kullanılmıştır.

Kalıp yapımı sırasında, "kolaylık payı" faktörünün giyen kişiye rahatlık sağladığı ve vücut hareketini kolaylaştırdığı düşünülmektedir. Hareket kolaylığı payı, kumaşın türüne ve kullanıcının vücut şekline ve vücut boyutlarına bağlıdır. Kullanıcıya doğru şekilde uyum ve rahatlık ile başarılı kalıp tasarımı için uygun kolaylık payı değeri esastır. Bu alan çok sayıda araştırmacının ilgisini çekmiştir. Örneğin, Chen ve ark. (2006), jean tipi pantolonlar için kolaylık toleransı ile ilgili unsurlar (giysinin yapısal parametreleri, kullanıcının rahatlık gereksinimleri ve kullanıcının vücut ölçüleri gibi) arasında iyi bir ilişki kurmak için matematiksel modeller geliştirmiş ve araştırmışlardır. Giyenlerin duyuşal değerlendirmesi açısından giysi kalıbı oluşturma ile başa çıkmak için akıllı bir model geliştirilmiştir. Bu model, kullanıcının rahatını kolaylaştırmak için kullanıcının vücut şekline ve boyutuna bağlı olarak yeni rahatlık toleransı değerlerinin üretilmesine yardımcı olmuştur. Kolaylık payına ilişkin bu çalışma başka bir çalışmada daha da genişletilmiştir (Chen ve ark., 2009). Kullanıcının temel vücut pozisyonları ve hareketleri arasında bir ilişki kurulmuştur. Toplam kolaylık payı, sıralı bir ağırlıklı ortalama alma operatörü kullanılarak tahmin edilmiştir. Araştırmanın verimliliğini araştırmak ve sonuçları doğrulamak için jean pantolonlar kullanılmıştır. Çalışma başarılı olmasına rağmen, diğer

giysi türlerini rahatlık payındaki etkinlik açısından doğrulamak için ek araştırma çalışmalarına ihtiyaç duyulmuştur.

Lin (2007), farklı durumlarda kıyafet seçerken müşterilerin talebini karşılamak için, tasarımcıların müşteriler için yenilikçi bir kıyafet stili tasarlamasına yardımcı olabilecek akıllı bir tasarım sistemi geliştirmiştir. Farklı giysi kombinasyonlarını aramak için arama işleminde GA tabanlı sistem kullanılmıştır. YSA, geliştirilen giysi giyme stillerinin kombinasyonlarını sınıflandırma mekanizmasını değerlendirmek için öğrenme ve bilgi edinme yoluyla sınıflandırıcıyı oluşturmak için kullanılmıştır. Bu sistem, moda tasarımı konusunda önceden bilgisi olmayan bir müşterinin, en iyi olan tasarım şemasını seçmesine yardımcı olabilmektedir. Bu araştırmanın sınırlılığı, yalnızca birkaç basit renk türünü dikkate alması olmuştur.

2.3.3. Üretim planlama ve kontrol

Üretim planlama ve kontrol (ÜPK), teslimat tarihlerinin karşılanması ve müşterilerin siparişlerinin zamanında teslim edilmesi için çeşitli üretim departmanları arasında koordinasyon sağlamaktadır. Çeşitli araştırma faaliyetleri, ÜPK ile ilgili sorunlara odaklanmakta ve darboğazı önlemeye çalışmaktadır (Wong ve ark., 2005; Guo ve ark., 2008). Çalışmaların çoğu, makine yerleşiminin düzenlenmesi, dikişte hat dengeleme ve dikişteki operatörlerin yönetilmesi gibi dikiş bölümüne ilişkin ÜPK'deki sorunlara dayanmaktadır. YZ, makine yerleşimi, operasyon ataması ve dikiş hattı dengeleme problemlerini çözmek veya optimize etmek için kullanılabilir. Bu durum, ÜPK'nin hedeflerine ulaşılmasına yardımcı olabilmektedir.

Chen ve ark. (2005), belirli bir müşteri siparişinde en uygun üretim tesisini belirlemek için karar vermede karar destek sistemi kullanmışlardır. Kararlar alınırken ölçülen verileri analiz etmek için GA kullanılmıştır. Elde edilen raporlar ve Gantt şemaları karar vericilerin seçim yapmasını kolaylaştırmıştır. Sistem, kullanımı kolay, senaryoları çalıştırabilecek ve küresel hazır giyim endüstrisine uygun olacak şekilde tasarlanmıştır. Wong ve ark. (2005) tarafından, dikim bölümünde ÜPK ile ilgili problemlerin üstesinden gelmek için yeniden planlamada GA tabanlı gerçek zamanlı bir segmentasyon geliştirilmiştir. Dikim öncesi aşamada üretim planlamasının en uygun çözümünü aramak için pastal planlama, serim, kesim ve demetleme işlemlerinin programlanması birleştirilmiştir. Önerilen yaklaşım uygulandıktan sonra planlamadaki sapmaların %44.42 ila %21,79 arasında iyileştirilebildiği görülmüştür.

Başka bir çalışmada, Guo ve ark. (2008) tarafından, uygun montaj hatlarına göre her bir üretim siparişi için üretim planlamada GA tabanlı bir sistem tasarlanmıştır. Bu sistem, üretim gecikmesi, üretim belirsizlikleri (işlem süresi, siparişler ve öncelikli varış süreleri gibi) ve diğer darboğazlar için çeşitli faktörler dikkate alınarak tasarlanmıştır. Üç farklı durum baz alınarak üç deney yapılmıştır: belirsiz işlem süresi, belirsiz sipariş ve belirsiz varış zamanları ile sipariş planlama. Önerilen yöntemin, deneyler için totalde %90 üzerinde memnuniyet seviyesine ulaşıldığını göstermiştir.

2.3.4. Son giysi kontrolü

Bitmiş ve yarı mamul giysilerin üretimleri sırasında denetlenmesi, daha az ret almak için çok önemlidir. Bitmiş bir giysinin nihai kalitesi, dikiş kalitesine ve diğer hatalara bağlıdır. Bitmiş giysilerin nihai kalite kontrolü, çoğunlukla deneyimli kişiler tarafından yapılmaktadır; bu, çok zaman alıcıdır ve doğası gereği çoğu zaman subjektiftir. Kontrolün sonuçları, kontrolcünün fiziksel ve zihinsel durumundan etkilenmektedir. Bu nedenle, verimliliğin artması ve doğru sonuçlar elde etmek için otomatik denetim cihazları gerekmektedir. Sınırlı sayıda çalışma yapılmış olmasına rağmen, bitmiş giysilerin kalite kontrolü için yapay zeka ve görüntü işleme kullanılarak otomatik kontrol gerçekleştirilebilmektedir (Yuen ve ark., 2009a).

Giysi üretimi sırasında her işlem (kesim, dikim ve ütü), bitmiş giysinin kalitesini etkileyen hayati bir rol oynamaktadır. Yarı mamullerin kalitesi, son kontrolden önce bu süreçlerin her birinde kontrol edilmelidir. Bitmiş giysiler, özelliklerine, genel görünümüne, hatalarına ve beden uyumlarına göre denetlenmektedir. Bitmiş giysiler, dikiş kalitesi, dikiş boyunca uyumsuz ekoseler veya çizgiler, büzülmüş dikiş veya dikişlere takılan ekstra malzeme, kenarlar boyunca düzensiz dikiş ve giysi üretimi sırasında ortaya çıkabilecek diğer birçok hata için ayrıntılı olarak incelenmektedir.

Yapay zekanın bitmiş giysi kontrolünde uygulanması şunları içermektedir: bilgisayarlı görme sistemleri kullanılarak gömlek yakalarındaki (tek renkli malzemeler için) genel hataların otomatik olarak sınıflandırılması (Norton-Wayne, 1990); Amerikan Tekstil Kimyagerleri ve Renk Uzmanları Birliği'nin bir lazer sensör kullanarak kırıxıklığın değerlendirilmesi için kırıxıklık derecelendirme uygulaması (Kim, 1999; Mori ve Komiyama, 2002); dalgacık dönüşümü ve GY sinir ağı kullanılarak dikiş hatalarının saptanması ve sınıflandırılması (Wong ve ark., 2009; Yuen ve ark., 2009b); kendi kendini organize eden haritalamayı kullanarak dikiş büzülme değerlendirmesi (Mak ve Li, 2008);

ve giysi kontrolü için akıllı bir askı tasarımı (Yuen ve ark., 2008). Dikişsiz giysilerin imalatında, YZ çevrimiçi hataları tespit etmek için kullanılabilir. Nihai giysinin görüntüsü yakalanıp ve standart giysi ile karşılaştırılabilir ve standarttan herhangi bir sapma o anda düzeltililecek bir hata olarak raporlanmakta veya hatanın olduğu yerde bir işaretleme yapılmaktadır (Nawaz ve Nayak, 2015).

Yuen ve ark. (2009b), çalışmalarında örme kumaş görüntülerini kullanarak, kumaş dikiş kontrol yöntemi geliştirebilmek ve kumaşları sınıflandırabilmek için üç sınıf belirlemiştir: (1) dikiş hataları olmayan dikişler; (2) kıvrılma hatalı dikişler ve (3) büzülme hatalı dikişler. Kumaş görüntüleri işlendikten sonra, sınıflandırma ve nesne tanıma için GY sinir ağı kullanılmıştır. GY sinir ağını kullanarak kumaşlardaki dikiş hatalarını tanıma oranı %100 olarak bulunmuştur. Kalkancı ve ark. (2017), süprem ve interlok kumaşlardan yapılmış tişörtlerin boyutsal ölçüm özelliklerini tahmin etmek için ileri beslemeli geri yayımlı YSA'nın kullanımını araştırmaktadır. Bu amaçla elastan içeren ve içermeyen üç farklı yoğunluktaki farklı malzemelerden oluşan iki kumaş grubunun her biri için toplam 72 farklı tipte tişört üretilmiştir. Konfeksiyon üretim sürecinin ardından nihai ürünün (T-shirt) boyutları tek tek alınarak kaydedilmiştir. Deneysel sonuçlar, model tarafından üretilen boyutsal özelliklerin tahmininin oldukça güvenilir olduğunu göstermiştir ($R^2 > 0,99$).

2.3.5. Tedarik zincirindeki uygulamalar

Tekstilde tedarik zinciri yönetimi (TZY), farklı üretim noktaları arasında veya perakende satışta liflerin, ipliklerin, kumaşların, giysilerin, süslemelerin ve aksesuarların akışını içermektedir. Ayrıca, bilgi akışı da dahil olmak üzere yukarıda listelenen tüm materyallerin depolanmasını ve kontrolünü içermektedir. TZY, müşteriler için değer yaratmada çeşitli iş süreçlerini, faaliyetleri, bilgileri ve kaynakları entegre etmektedir. Uygun TZY, maliyeti ve ticari rekabet gücünü yönetebilmektedir. Diğer ürünlerin tedarik zinciri faaliyetlerinde geniş bir YZ uygulaması olmasına rağmen, moda tedarik zincirinde sınırlı uygulamanın olduğu birkaç alan bulunmaktadır (Nayak ve Padhye, 2018).

YZ esaslı modeller, TZY'nde herhangi bir noktada bilgi entegrasyonu ve paylaşımı için kullanılabilir (Lo ve ark., 2008; Au ve ark., 2006). Tedarik zinciri planlaması (Chiu ve Lin, 2004); tedarik zinciri talep tahmini (Carbonneau ve ark., 2008); tedarik zinciri ağının optimizasyonu (Yu ve ark., 2011); tekstil tedarik zincirinde lojistiği yönetmek (Chandra ve Kumar, 2000); numune yönetimi (Choy ve ark., 2009); etkili envanter

yönetimi (Paul ve Azeem, 2011); ve envanter yenileme (Dong ve Leung, 2009; Pan ve ark., 2009) için çeşitli YZ yaklaşımları kullanılabilir.

Arıkan Kargı (2016), gömleklik kumaş üreten bir tekstil firmasının çeşitli alternatifler arasından en uygun iplik tedarikçisini seçmesine yardımcı olacak bir çalışma yapmıştır. Bulanık bir ideal çözüme göre tercih sırası tekniği yöntemi kullanarak karar sürecini basitleştirmeye çalışmışlardır. Tedarikçi alternatiflerini değerlendirmek amacıyla literatür bilgileri ve firma karar vericilerinin görüşleri yardımıyla beş karar kriteri belirlenmiştir. Bunlar kalite, fiyatlandırma, teslimat süresi, teknoloji ve esnekliktir. Bu uygulamadaki alternatiflerin yakınlık katsayıları incelendiğinde ilk firma alternatifinin (0,65) ile en yüksek katsayı değerine sahip olduğu ve birinci sırada yer aldığı görülmüştür. Diğer alternatiflerin daha düşük katsayılara (0,42 ve 0,44) sahip olduğu görülmüştür.

2.3.6. Perakendecilikteki uygulamalar

Tekstil perakendeciliği, tekstil ürünleri üreticileri ile tüketiciler arasındaki bağlantıyı kurmaktadır. Son yirmi yılda, tekstil perakendeciliği, teknolojik gelişmeler ve tüketicilerin moda yönüne yönelik hızlı davranış değişiklikleri nedeniyle en rekabetçi perakende sektörlerinden biri haline gelmiştir. YZ uygulamasının giderek arttığı, satış tahmini (Yu ve ark., 2011; Sun ve ark., 2008); moda perakende satış tahmini (Au ve ark., 2008; Xia ve ark., 2012); tüketicilere stil önerisi (Hsu ve ark., 2009); müşteri ilişkileri yönetimi (Ngai ve ark., 2009; Groves ve Valsamakis, 1998); talep tahmini (Fumi ve ark., 2013); müşteri memnuniyetini belirleme (Goode ve ark., 2005); ve moda koordinasyonu gibi perakendecilikte birkaç alan bulunmaktadır.

YZ öneri sistemleri, tüketiciler için uygun stil ve tasarım kombinasyonunun seçilmesi için kullanılabilir (Ding ve Xu, 2008; Hsu ve ark., 2009). Bazı durumlarda, iki farklı stil arasındaki ince farkları belirlemek çok zordur. YZ, iki veya daha fazla farklı stil arasındaki farklılıkları ve benzerlikleri belirlemek için kullanılabilir. Örneğin, Koehl ve ark. (2008), kumaşların moda temaları arasındaki farklılığı ve benzerliği karakterize etmek için BM tabanlı YZ kullanmışlardır. YZ tarafından tanımlanan moda temaları arasındaki farklılık, tüketicinin moda seçimleri ile kumaşların teknik parametreleri arasında ilişki kurabilen girdi alanının alaka düzeyini analiz etmek için kullanılabilir.

Tüketiciler kumaş tuşesinin yanı sıra kumaşın dokusunu da incelemeye çalışırlar. Kumaş dokusu, bir tekstil yüzeyinin kalitesidir. Doku pürüzlü veya pürüzsüz olabilir ve bir giysinin tasarım sürecini büyük ölçüde etkilemektedir. Bir kumaşın dokusunu araştırmak

için birçok araştırma yapılmıştır. Örneğin, kumaş dokusu oluşturmada optimum sonuçlar elde etmek için Muni ve ark. (2006), genetik programlama kullanarak etkileşimli bir doku oluşturma süreci geliştirmişlerdir.

Alkap (2019), ring ve open end iplik üretimi gerçekleştiren iki adet iplik firmasına ait 2013-2018 dönemi iplik satış rakamlarını kullanarak ekonomik ve firma performans parametreleri girdileri ile gelecek dönem iplik satış miktarları tahmini için YSA yöntemi kullanmıştır. Dalgalı döviz kuru ve ekonomik şok anlarında iplik talebinde meydana gelen değişimler modelde incelenerek, bir iplik firmasının üretim planlama ve finansal yönetimi açısından karar destekleyici bir sistem tasarımı sunulması amaçlanmıştır. Bu amaçla geliştirilen bir YSA modelinde R değeri aralığı 0.80 ve 0.87 olarak bulunmuş ve yüksek bir ilişki gözlemlenmiştir.



3. ÖNCEKİ ÇALIŞMALAR

3.1. Şönil İplik ve Şönil Kumaşla İlgili Çalışmalar

Çeven ve ark. (2007) tarafından yapılan çalışmada, radyal taban fonksiyonlu sinir ağı modelleri kullanarak şönil iplik ve kumaşın aşınma direncinin tahmini üzerine çalışılmıştır. İpliklerin üretiminde hav ipliği için altı farklı hammadde (viskon, 0,9 dtex akrilik, 1,3 dtex akrilik, penye pamuk, karde pamuk ve open end pamuk) kullanılmıştır. Hav uzunluğu 0,7 ve 1 mm, büküm 700 ve 850 tur/m ve iplik numarası Nm4 ve Nm6 olacak şekilde farklı kombinasyonlarla 48 adet numune üretilmiştir. Yapay sinir ağı modeli için girdi olarak iplik numarası, hav uzunluğu, büküm seviyesi ve hav ipliği malzeme tipi gibi şönil iplik parametreleri kullanılmıştır. Tahminleme modeli, farklı istatistiksel modellerle karşılaştırılmıştır. Ortalama mutlak hata değerleri, iki istatistiksel yöntem ve akıllı model ile şönil kumaş için, sırasıyla 3.62, 3.39 ve 2.93 olarak; şönil iplik için ise 1.18, 0.86 ve 0.80 olarak bulunmuştur. Akıllı modelin istatistiksel modellere göre tahmin performansının daha iyi olduğu görülmüştür.

Çeven ve Özdemir (2007) tarafından yapılan çalışmada, şönil iplik çekme davranışını değerlendirmek ve tahmin etmek için bulanık mantık kullanılmıştır. Şönil iplikler, bir şönil iplik makinesinde farklı iplik numaraları, hav uzunlukları ve büküm seviyelerinde üretilmiştir. Bu tür ipliklerin üretiminde özlü iplik bileşeni akrilik, hav ipliği bileşeni ise viskon olarak seçilmiştir. Şönil ipliklerin kaynar su çekmesi, bir laboratuvar test yöntemine göre ölçülmüştür. Bulanık mantık modelini kurmak ve temel ilkeleri oluşturmak için deneysel veriler kullanılmıştır. Elde edilen sonuçlara göre, daha yüksek büküm seviyelerine ve daha kısa hav uzunluklarına sahip şönil ipliklerin çekme değerlerinin daha düşük olduğu, iplik numarasının da çekme üzerinde önemli bir etkiye sahip olduğu görülmüştür. Bulanık mantık modelinden elde edilen sonuçların gerçek sonuçlarla karşılaştırılması, ölçülen ve tahmin edilen iplik çekme değerleri arasında güçlü bir doğrusal ilişki ($R=0.985$) olduğunu göstermiştir.

Tunak ve ark. (2011) tarafından yapılan çalışmada, şönil ipliklerde meydana gelen çeşitli hata tiplerinin izlenmesi için bir kontrol diyagramı tanıtılmıştır. Kontrol diyagramını uygulamak için, bir görüntü matrisi olarak şönil ipliğin gri seviyeli bir görüntüsü yakalanmıştır. İkili görüntüyü eşikleme ve görüntüden küçük nesnelere çıkarmak için morfolojik bir açma işlemlerinden oluşan görüntü ön işleme uygulanmıştır. İşlenen görüntülerden ölçülen hav ipliğinin yüksekliği, izlenen kalite özelliği olarak seçilmiştir.

İzlenen kalite karakteristiği yüksek oranda otokorelasyona sahip olduğundan, otokorelasyon yapısını modellemek için birinci dereceden otoregresif AR(1) modelinin uygun olduğu bulunmuştur. AR(1) proses parametrelerinin tahminine bağlı olarak, modifiye edilmiş üstel ağırlıklı hareketli ortalama kontrol diyagramı, uygun AR(1) modelinin artıklarını izlemek için kullanılmıştır. Modifiye edilmiş kontrol diyagramının farklı tipteki şönil iplik hatalarını izlemek için başarılı bir şekilde kullanılabileceği gösterilmiştir.

Tekeoğlu ve Kavuşturan (2011), şönil ve makarna döseme kumaşların kopma mukavemeti ve aşınma direnci özelliklerini araştırmışlardır. Şönil ve makarna iplik üretiminde dört farklı hammadde kullanılmıştır: akrilik, polyester, pamuk ve viskon. Sonuçların değerlendirilmesi için istatistiksel yöntem kullanılmıştır. Her iki kumaş çeşidinde, kopma mukavemetinin ve aşınma direncinin kullanılan hammadde ve fantezi iplik yapısından etkilendiği görülmüştür. Makarna ipliklerin daha düşük aşınma direnci ve daha yüksek mukavemete sahip olduğu görülmüştür. Şönil kumaşların aşınma sonrası ağırlık kaybının daha fazla olduğu ve makarna kumaşların daha yüksek stres değerlerine sahip olduğu tespit edilmiştir. Pamuk ve polyester ipliklerin daha az aşındığı; polyester iplik ve kumaşların daha yüksek kopma mukavemetine sahip olduğu görülmüştür.

Babaarslan ve Telli (2013) tarafından yapılan çalışmada bir fantezi iplik çeşidi olan şönil ipliklerin giyim konforunu geliştirerek denimde kullanılabilirliği araştırılmıştır. Aynı gramajdaki klasik denim kumaşla atkısında şönil ipliği kullanılmış denim kumaşın kopma mukavemeti, kopma uzaması, yırtılma mukavemeti ve aşınma dirençleri arasındaki fark incelenmiştir. Sonuç olarak şönil ipliğin tipik özelliği olan düşük aşınma değerlerinin aksine, tahmin edilenlerden farklı sonuçlar elde edilmiştir. Ayrıca elde edilen kumaşın yırtılma mukavemeti, kopma mukavemeti ve uzaması bakımından da kabul edilebilir seviyelerde değerler aldığı görülmüştür.

Süle (2014) tarafından, şönil ipliğin ekseninde gözlenen yerel bir yapısal dokunun boyutlarını doğrudan belirlemek için yeni ve hızlı bir görüntü analizi esaslı yöntem, yani aksinel gri seviye (EGS) karakteristiğinin çıkarılması sunulmuştur. Helisel olarak sarılmış özlü ipliklerden oluşan dokudan elde edilen EGS sinyali, büküm seviyesinin ve varyasyonlarının belirlenmesini sağlamıştır. Ek olarak, algoritmik eşikleme işlemi kullanılarak büküm seviyesini elde etmek için eliptik kesitli sarmal ipliğin parametrik denklemini içeren çok adımlı gradyan tabanlı eşikleme adlı yeni bir dolaylı yöntem geliştirilmiştir. Hough Dönüşümü yöntemi, yeni yöntemle elde edilen büküm ve büküm

oryantasyon deęerlerinin doęrulanmasını saęlamıştır. Büküm seviyesinin belirlendięi görüntü bölgelerine karşılık gelen sinyal deęişikliklerini deęerlendirmek için bilgisayarlı görüş ünitesi ile birlikte optoelektronik sensör içeren bir iplik kontrol sistemi geliştirilmiştir.

İlhan ve Yarar (2015) tarafından yapılan çalışmada, bir fantezi iplik çeşidi olan şönil iplikte büküm daralmasına etki eden faktörler teorik ve istatistiksel yaklaşımlarla araştırılmıştır. Bu araştırmanın amacı, üretim öncesi şönil iplikte büküm daralmasını tahmin etmek için bir model geliştirmek olmuştur. Teorik yaklaşımda geometrik yöntemlerle matematiksel bir model geliştirilmiştir. Farklı seviyelerde etkili faktörler içeren bir deney tasarımına göre yirmi yedi farklı şönil iplik numunesi üretilmiştir. İstatistiksel yaklaşımda, veri setleri 20 ve 7 olmak üzere iki kısma ayrılmıştır. 20 tanesine aşamalı regresyon analizi uygulanmış ve anlamlı bir model elde edilmiştir. Kalan veri setleri doęrulama için kullanılmıştır. Son olarak, matematiksel ve istatistiksel modeller doęrulanmış ve büküm daralmasını tahmin etmek için performansları karşılaştırılmıştır. Sonuç olarak, regresyon modelinin performansının matematiksel modelden biraz daha iyi olduęu kanıtlanmıştır. Bununla birlikte, her iki model de şönil ipliklerde büküm daralması için kabul edilebilir tahmin deęerleri vermiştir.

İlhan (2017) şönil iplikte mukavemet ve uzama özellikleri ile ilgili olarak bir çalışma yapmıştır. İplik numuneleri %100 penye iplikten üretilmiştir. İpliklerin hav uzunlukları 1 mm olarak bütün numunelerde sabit tutulmuştur. Şönil ipliklerde bağ ve hav iplięi olarak 3 farklı numarada iplik kullanılmıştır. Ayrıca 3 farklı büküm seviyesi bu ipliklerin üretiminde kullanılmıştır. Bu parametrelerin kombinasyonlarıyla 27 farklı şönil iplik numunesi üretilmiştir. Numunelerden 20 tanesi istatistiksel analiz için kullanılmış, 7 tanesi ise doęrulama için ayrılmıştır. Ayrıca bütün numuneler için matematiksel yöntem ile de tahminleme yapılmıştır. İki yöntemin performansı deęerlendirilmiştir.

Esi ve Baykal (2020), standart ştapel polyester (PES) iplikler ve atık PET şişeleri geri dönüştürerek elde ettikleri geri dönüştürülmüş polietilen tereftalat (r-PET) iplikleri bağ ve hav iplięi olarak kullanarak şönil iplik elde etmişlerdir. İplik türü, iplik numarası, hav uzunluęu gibi faktörler ile çeşitli kombinasyonlarda 16 çeşit şönil iplik üretimi gerçekleştirilmiştir. Daha sonra bu iplikler atkıda kullanarak dokuma kumaş elde edilmiştir. %100 r-PET ipliklerden, yani bağ ve hav ipliklerinin her ikisinde de r-PET kullanılmış ipliklerden üretilen dokuma kumaşlarda atkı kopma mukavemetlerinin dięer

türlere göre bir miktar azaldığı, ancak bu azalmanın istatistiksel olarak anlamlı olmadığı görülmüştür.

Fouda ve ark. (2021), iplik bükümü, hav yüksekliği ve ilmek uzunluğu parametrelerinin, kış aylarında dış giyimde kullanılan şönil kumaşlarda, geometrik, fiziksel ve termofizyolojik özellikleri üzerindeki etkisini araştırmışlardır. Ayrıca, seçilmiş parametrelerin kumaş aşınma direncine etkisi incelenmiştir. Şönil iplik üretiminde, 700 ve 850 tur/m büküm, 1, 1.2 ve 1.5 mm olmak üzere üç farklı hav yüksekliği ile 40 tex şönil ipliği üretilmiştir. Kumaş üretimi için 1, 1.2 ve 1.4 cm olmak üzere üç farklı ilmek uzunluğu seçilmiştir. Böylece 18 adet düz örme kumaş numunesi üretilmiştir. Sonuçlar istatistiksel olarak analiz edilmiştir. Test edilen kumaş özelliklerini etkileyen en belirgin faktörün kumaş ilmek uzunluğu, sonrasında şönil iplik hav yüksekliği ve ardından şönil iplik büküm seviyesi olduğu bulunmuştur. Hav yüksekliği ve büküm arttıkça ısıl direnç ve iletkenlik artarken hava geçirgenliği ve su buharı direnci azalmıştır.

3.2. Tekstilde Yüzey Özelliği Çıkarmaya İlgili Çalışmalar

Shin ve ark. (2010), belirli bir tekstil ürününden belirli insan duygusal kavramlarını otomatik olarak tahmin edebilen bir duygu tahmin sistemi sunmuşlardır. Önerilen yöntemde, renk ve desen, bir görüntüyle ilişkili duygusal anlamı tahmin etmek için ipuçları olarak kullanılmıştır. Bu özellikler, sırasıyla renk nicemleme ve çok düzeyli dalgacık dönüşümü kullanılarak çıkarılmıştır. Çıkarılan özellikler daha sonra üç temsili sınıflandırıcıya uygulanmıştır: K-ortalama kümeleme, Naïve Bayes ve çok katmanlı algılayıcı. 3600 tekstil görüntüsü kullanılarak önerilen duygu tahmin yöntemi değerlendirildiğinde çok katmanlı algılayıcı en iyi performansı üretmiştir. Önerilen çok katmanlı algılayıcı, yalnızca renk veya desen kullanan diğer yöntemlerle karşılaştırıldığında, %92'nin üzerinde doğrulukla en iyi performansı göstermiştir.

Jing ve ark. (2014), üç dokuma kumaşı (bezayağı, dimi ve saten) için doku özelliklerini tanıyan hızlı ve otomatik bir tanımlama sistemi kurmayı denemişlerdir. İlk aşamada, ön işleme sonrası dokuma kumaş görüntülerinden özniteliklerin çıkarılması için, Gri Seviye Eş-oluşum Matrisi ve Gabor Dalgacıkları kullanarak daha global ve yerel görüntü özellik değerleri elde edilmiştir. Daha sonra iki özelliği özellik setleri olarak birleştirerek, temel bileşen analizi aracılığıyla düşük boyutlu ve gerekli temel bileşen özellik vektörleri elde edilmiştir. Son olarak olasılıksal sinir ağı tarafından üç temel dokuma kumaş tanınmıştır.

Diğer sinir ağı sınıflandırıcılarla karşılaştırıldığında, olasılıksal sinir ağının daha hızlı eğitim hızı ve daha yüksek verimlilik ile önemli avantajlara sahip olduğu bulunmuştur.

Yapi ve ark. (2015), bir makine öğrenimi yaklaşımı kullanarak tekstil hata tespit problemini ele almıştır. Uygun özellik çıkarma ve sınıflandırmaya dayalı olarak tekstil dokularını hatalı ve hatasız olarak sınıflandırmak için denetimli öğrenmeyi kullanan yeni bir algoritma önerilmiştir. Doku tanımlamasında, kompakt ve doğru sinyaller elde etmek için çok ölçekli kontür görüntü ayrıştırmasının istatistiksel modellemesi kullanılmıştır. Hata tespit algoritması iki aşamaya dayandırılmıştır. İlk aşamada, görüntülerden bir eğitim seti kullanarak, her tekstil kategorisi için referans hatasız sinyaller çıkarılmıştır. Ardından, hatalı ve hatalı olmayan sınıfların sinyallerini öğrenmek için Bayes sınıflandırıcısı kullanılmıştır. İkinci aşamada, eğitilmiş Bayes sınıflandırıcısı ve görüntülerin bloklara uygun bir şekilde ayrıştırılması kullanılarak yeni görüntülerde hatalar tespit edilmiştir. Algoritma, verimli bir hesaplama süresi sağlarken, tekstil dokularında son derece hassas hata tespiti ve lokalizasyon elde etme yeteneği elde edilmiştir.

Gürgen (2019), tez çalışmasında tekstil tipi tanıma probleminin karmaşık yapılar, sensör tabanlı sistemler kullanılmadan herhangi bir kamera ile elde edilecek fotoğraf ile çözülmesini amaçlamıştır. Çalışma, derin öğrenme tekniklerinden evrişimli sinir ağları ile gerçekleştirilmiştir. Sınırlı sayıda bulunan benzer bir çalışma için daha önceden hazırlanmış veri seti kullanılmıştır. Bu amaçla, VGG16, VGG19, InceptionResNetV2, MobileNetV2, ResNet50 ve InceptionV3 evrişimli sinir ağı (ESA) mimarileri kullanılarak detaylı sonuçlar elde edilmiş ve birbirleriyle karşılaştırılmıştır. ResNet50 ve InceptionResNetV2 ile istenilen sonuçlar elde edilememiş ancak diğer 4 mimari ile test veri kümesi ile yüksek doğruluk oranları elde edilebilmiştir. Ayrıca probleme özgü bir ESA mimarisi önerilmiştir. VGG16 ve önerilen ESA modeli birlikte kullanıldığında doğruluk oranının %1 arttığı görülmüştür.

Yıldız (2019) tarafından yapılan çalışmada, yüzey analizine dayalı bir tanıma yöntemi kullanarak yün lifini tiftik lifinden ayırmak için nesnel, kolay, hızlı ve uygun maliyetli bir yöntem tasarlanmıştır. Bu amaçla hem yün hem de tiftik liflerinin mikroskobik görüntüleri yüzey görüntüleri olarak ön işleme tabi tutulmuştur. Liflerden belirleyici bilgiler elde etmek için yerel ikili örüntü tabanlı özellik çıkarma işlemi ve derin öğrenme ayrı ayrı kullanılmıştır. Örneklerin belirlenmesi için sınıflandırmaya dayalı yöntem kullanılmıştır. Deneysel sonuçlar, bu tür hayvan lifleri için doğru bir yüzey analiziyle, sırasıyla %99,8 ve

%90,25 doğruluk oranlarıyla derin öğrenme ve makine öğrenimi kullanarak yün ve tiftik liflerini tanımanın mümkün olduğunu göstermiştir.

Zhao ve ark. (2019) tarafından, üretilen tekstil liflerinin kalitesini saptamak ve değerlendirmek için nispeten basit ve etkili bir teknik önerilmiştir. Kumaş hatalarının otomatik görsel kontrolünü gerçekleştirmek için öncelikle tekstil kumaşının görüntüleri Blok Eşleştirme ve 3-D filtreleme kullanılarak işlenmiştir. Daha sonra sırasıyla renk, doku ve frekans spektrumu özellikleri olmak üzere tekstil lifleri görüntüsünün özellikleri çıkarılmıştır. Renk özellikleri, insan görme algısı modeliyle daha tutarlı olan ton-doygunluk-yoğunluk modeli kullanılarak çıkarılmıştır; doku özellikleri, yerel görüntü özelliklerini tespit etmek ve tanımlamak için oldukça iyi bir yöntem olan ölçekle değişmeyen özellik dönüştürme şeması kullanılarak çıkarılmıştır. Tekstillerin frekans spektrumu özelliklerinin ise, mekansal özelliklere göre gürültü ve yoğunluk değişimlerine karşı daha az hassas olduğu bildirilmiştir. Son olarak, kumaş kalitesini gerçek zamanlı olarak değerlendirmek için, tepe sinyal-gürültü oranı ve yapısal benzerlik olmak üzere iki kantitatif metrik parametre, tekstil kumaş görüntüsünün kalitesini objektif olarak değerlendirmede kullanılmıştır. Tekstillerin kalitesini verimli bir şekilde tespit edebilen ve değerlendirebilen, böylece tekstil üretim hatlarının verimliliğini artıran, tekstil kumaş görüntü özelliğine dayalı akıllı bir algılama ve değerlendirme yöntemi önerilmiştir.

Cui ve Xue (2020) tarafından yapılan çalışmada, çok renkli fantazi ipliklerin önemli yüzey özelliklerinin çıkarılması için bir çerçeve önerilmiştir. Fantazi ipliğin görüntüsünü kaydetmek için bir görüntü yakalama aparatı kullanılmıştır. Ardından, yakalanan dijital görüntüler, görüntü grileştirme, filtreleme ve morfoloji işleme olmak üzere nesnenin dijital görüntülerini yeniden oluşturmak için uzamsal olarak karşılık gelen piksel noktaları üretmek üzere işlenmiştir. Son olarak, fantezi ipliklerin yüzey özelliklerini çıkarmak için farklı segmentasyon yöntemleri kullanılmış ve her fantezi iplik türü için en uygun segmentasyon yöntemi incelenmiştir.

Gültekin ve ark. (2020) tarafından yapılan çalışma, su karıştırılmış nonwoven kumaşların lif dağılımı ile geçirgenlik özellikleri arasındaki ilişkiyi hava geçirgenliği ve gözeneklilik açısından araştırmak için yapılmıştır. Su karıştırılmış nonwoven kumaşların lif dağılımı ve ağ özellikleri, bitmiş ürünlerin mekanik ve fiziksel performansı üzerinde önemli bir etkiye sahiptir. Bu özelliklerin üretim sırasında fiziksel test yapılmadan kontrol edilmesi, üretim maliyetlerini, malzeme atıklarını ve proses parametrelerini değiştirmek için gerekli sürenin azaltılmasında önemli bir rol oynadığı görülmüştür. Bu çalışmada, su karıştırılmış

nonwoven kumaşların yüzey özelliklerinden, gözeneklilik ve hava geçirgenlik özelliklerini tahmin etmek için yapay zeka yöntemi geliştirilmiştir. Bu amaçla, kumaş gözenekliliğini ölçmek ve yüzey istatistiksel özelliklerini çıkarmak için iki görüntü işleme algoritması geliştirilmiştir. İncelenen kumaş özelliklerinin tahmini için bir YSA modeli oluşturulmuştur. Farklı alan ağırlıklarına sahip polyester ve viskon lifleri numune olarak kullanılmıştır. Hem gözeneklilik hem de hava geçirgenliği özellikleri için, tahminlenen ve gerçek değerler arasında yüksek regresyon değerleri elde edilmiştir. YSA sonuçlarına göre, su karıştırılmış nonwoven kumaşların hava geçirgenliği ve gözeneklilik özelliklerinin yüzey görüntülerinden yüksek doğrulukla tahmin edilebileceği ortaya çıkmıştır.

Nazir ve ark. (2021), çalışmalarında bir özellik çıkarma yöntemi kullanmışlardır. Öncelikle görüntü yeniden boyutlandırılmış ve gri tonlama düzeyine dönüştürülmüştür. Daha sonra şekil ve doku özelliği çıkarma yöntemlerine göre özellikler çıkarılmıştır. Doku özelliklerini bulmak için, ayırık dalgacık dönüşümü ve yerel ikili örüntü, şekil özellikleri için ise değişmeyen momentler kullanılmıştır (çoklu tanımlayıcıların bileşimi kullanılmıştır). Görüntüyü yumuşatarak gürültüyü ortadan kaldırmak için Canny kenar bulma yöntemi kullanılmıştır. Özellik tanımlayıcıların boyutunu azaltmak amacıyla temel bileşenler analizi kullanılmıştır. Deneysel sonuçlarda aynı ve farklı bir desen için 300 batık görsel kullanılmıştır. Sınıflandırma yöntemi olarak Destek Vektör Makinesi yöntemi kullanılmıştır. Genel sonuç, çoklu özellikler kombinasyonunun, tekli özellik çıkarma yöntemiyle karşılaştırıldığında etkili sonuçlar verdiğini göstermiştir. Temel bileşenler analizi algoritması uygulandıktan sonra sistemin doğruluğu yaklaşık %97,6 olarak bulunmuştur (uygulanmadan önce yaklaşık %80 doğruluk sağlanmıştır).

Kim ve ark. (2021), bir dikiş işleminin yakalanan görüntüsünden kopmuş bir dikişi tespit etmek için, önceden eğitilmiş VGG-16'nın başlangıç katmanlarından çıkarılan ve evrişimli sinir ağı özellik haritasını kullanan bir dikiş hatası tespit yöntemi önermişlerdir. Önerilen yöntemin etkinliğini değerlendirmek için, normal görüntüler, bunların yapay hataları ve döndürülmüş görüntüleri dahil olmak üzere bir dizi dikiş görüntüsü üzerinde denemeler yapılmıştır. Sonuç olarak önerilen yöntemin gerçek hataları %92,3 doğrulukla tespit ettiği görülmüştür. Ayrıca, gerçek zamanlı hesaplama için gereken hesaplama süresini azaltmak amacıyla bilgi işlem cihazları ve derin öğrenme kütüphaneleri için ek koşullar araştırılmıştır. Görüntüyü yeniden boyutlandırılan ve hafif bir derin öğrenme kütüphanesinden yararlanan genel ve ucuz bir tek kartlı bilgisayar kullanıldığında hesaplama süresi 0,22 saniye olarak bulunmuştur. Sonuçlar, önerilen yöntemin

performansının giysi üretimi için uygun bir üretim teknolojisi olarak uygulanabilirliğini doğrulamıştır.

Seçkin ve Seçkin (2021) tarafından yapılan çalışmada, kumaş hata tespiti için daha hızlı ve daha yüksek doğruluk sağlayan yeni bir yüzey özelliği çıkarma yöntemi sunulmaktadır. Geliştirilen yöntem temel olarak görüntüden alınan bir pencereden özellik çıkarma işlemidir. İç içe geçmiş çerçeveler, pencereyi oluşturan matriste tanımlanmıştır. Her çerçeve için bir ağırlık merkezi tanımlanmıştır. Her çerçeve için, merkez pikselden ağırlık merkezine bir çerçeve vektörü çizilmiştir. Çerçeve vektörleri arasındaki çeşitli vektör fonksiyonlarının sonuçları yüzey özellikleri olarak kullanılmıştır. Bu özellikler, hata tespiti için sınıflandırma algoritmalarında kullanılmıştır. AITEX veri seti kullanılmış ve önerilen yöntem geleneksel yüzey özelliği çıkarma yöntemleri ile performans ve zaman açısından karşılaştırılmıştır. Önerilen yöntemin en hızlı algoritmaya göre %55 daha hızlı çalıştığı ve en az %1.8 daha doğru sonuçlar verdiği gösterilmiştir.

Talu ve ark. (2022), yeni bir gerçek zamanlı kumaş hata tespit sistemi önermişlerdir. Önerilen endüstriyel görüş sistemi bir tezgah üzerinde gerçek zamanlı olarak çalıştırılmıştır. İlk olarak, gerçek kumaş görüntüleri ve yeni hatalı yama yakalama algoritması kullanılarak iki kumaş veri tabanı oluşturulmuştur. Bu çalışmanın temel amaçlarından biri yalnızca yapı hata tespitine odaklanan bir evrişimli sinir ağı mimarisi geliştirilmesidir. Çalışmanın en özgün yönlerinden biri, kumaş görüntülerinin hatalı piksel bölgelerini yama tabanlı Fourier analizi ile tespit edip derin öğrenmeyle entegre edilmesidir. Yeni geliştirilen hızlı Fourier dönüşümü tabanlı hatalı yama yakalama algoritması sayesinde, karmaşık denim kumaş dokularında bile hatalı doku alanları görünür hale getirilmiştir. İkinci olarak uygun bir evrişimli sinir ağı modeli geliştirilmiştir. Böylece model iyileştirilmiştir. Derin modellerin ve geleneksel modellerin sınıflandırma performanslarını karşılaştırmak için geleneksel özellik çıkarımı ve sınıflandırma yaklaşımları da kullanılmıştır. Önerilen modelin hatalı görüntüleri yüksek doğrulukla sınıflandırabildiği görülmüştür (%96,5 doğrulukla).

Yaşar Çıklaçandır ve ark. (2023), farklı özellik çıkarma yöntemlerinin ve farklı sınıflandırıcıların analiz edilmesine; kombinasyonların avantaj/dezavantajlarının tartışılmasına; diğer çalışmalardan farklı olarak özellik çıkarımı için özellik füzyonunun kullanılmasına odaklanmışlardır. Desenli ve desensiz kumaşların hatalı ve hatasız olarak ayrılması için, eldeki kumaş veri kümelerini farklı açılardan ele alan ve farklı özellik çıkarma (evrişimli sinir ağı, minimum alaka ve maksimum artıklık) ve sınıflandırma

(topluluk öğrenme, k-en yakın komşu, destek vektör makinesi) yöntemleri uygulayan farklı durumlar oluşturulmuştur. ResNet18, özellik çıkarımında en yüksek performansa sahip evrişimli sinir modeli olup topluluk öğrenme ve destek vektör makinesi modelleri ile, sınıflandırmada birbirine yakın ve oldukça başarılı sonuçlar elde edilmiştir.

3.3. Tekstilde Yapay Sinir Ağları ile İlgili Çalışmalar

Zeydan (2007), YSA ve Taguchi deney tasarımı metodolojilerini kullanarak elyaf, iplik ve kumaş parametreleri ile kumaş mukavemeti arasındaki çoklu doğrusal ilişkiyi modellemeyi amaçlamıştır. Optimum tasarım değerlerini ve her parametrenin katkısını belirlemek için Taguchi deney tasarımı uygulanmıştır. Modellerin performansı, kök ortalama kare hatası ile ölçülmüştür. Taguchi deney tasarımı ve YSA metodolojileri ile oluşturulan modeller gerçek deneysel verilerle karşılaştırılmıştır. YSA modelinin minimum hata ile daha iyi yaklaşım sağladığı bulunmuştur. Bu çalışmada oluşturulan YSA modeli, firmadaki planlama departmanındaki mühendislerin, üretim siparişinden önce kumaş mukavemetini iyi bir şekilde tahmin ederek kumaş imalatını kolayca planlamalarına yardımcı olmaktadır.

Majumdar ve ark. (2008), düz dokuma kumaşların çekme mukavemetinin, YSA ve doğrusal regresyon olmak üzere iki ampirik modelleme yöntemi kullanılarak tahmin edilmesi üzerine çalışmışlardır. Girdi parametreleri olarak çözgü ipliği mukavemeti, çözgü ipliği uzaması, çözgü sıklığı, atkı sıklığı ve atkı ipliği numarası kullanılmıştır. YSA modeli, regresyon modelinden daha yüksek tahmin doğruluğu ve genelleme yeteneği göstermesine rağmen, her iki model de kumaş mukavemetini oldukça iyi bir hassasiyetle tahmin edebilmiştir. Çözgü ipliği mukavemeti ve çözgü sıklığı, çözgü yönünde kumaş mukavemetini etkileyen en önemli iki faktör olarak bulunmuştur.

Özçelik (2009), farklı pamuk harmanları kullanılarak, farklı iplik numarası ve iplik büküm katsayısında üretilen ipliklerden örülen interlok örme kumaşlarda, kumaşların boncuklanma özelliğinin tahminlenmesini sağlayacak denklemler ve modellerin elde edilmesini hedeflemiştir. Boncuklanmış kumaşların değerlendirilmesinde görüntü analizi yöntemi prensibine göre çalışan PillGrade Objektif Boncuklanma Değerlendirme Sistemi kullanılarak, kumaşların boncuklanma derecesi, toplam boncuk sayısı, ağırlıklı toplam boncuk sayısı, ortalama boncuk alanı, ortalama boncuk yüksekliği, ortalama hav yüksekliği değerleri tespit edilmiş ve bunlar bağımlı değişken olarak kullanılmıştır. Lif, iplik ve kumaş özellikleri ise bağımsız değişken olarak kullanılmıştır. Statistica ve Minitab istatistik programları aracılığıyla çok değişkenli doğrusal regresyon ve YSA yöntemleri ile

tahminleme analizleri gerçekleştirilmiştir. Sonuçlar her bir bağımsız değişken için ayrıntılı olarak değerlendirilmiş ve YSA yöntemlerinden daha iyi sonuçlar alınmıştır (Kumaşların boncuklanma derecesi, toplam boncuk sayısı, ağırlıklı toplam boncuk sayısı, ortalama boncuk alanı, ortalama boncuk yüksekliği, ortalama hav yüksekliği için sırasıyla YSA ile 0.85, 0.86, 0.79, 0.74, 0.72 ve 0.68, regresyon ile 0.73, 0.78, 0.64, 0.67, 0.69 ve 0.52 regresyon katsayısı değerleri elde edilmiştir).

Midha ve ark. (2010), yüksek hızlı endüstriyel dikiş sırasında ipliklerdeki mukavemet kaybını tahmin etmek için YSA modeli tasarlamışlardır. Çalışma için dört farklı tipte iplik (Merseyize pamuk, polyester ştapel, polyester-pamuk özlü ve polyester-polyester özlü) kullanılmıştır. Diğer girdi parametreleri olarak iplik doğrusal yoğunluğu, kumaş alanı yoğunluğu, kumaş katmanlarının sayısı, dikiş yoğunluğu ve iğne boyutu alınmıştır. Sonuçların, verilerin eğitim ve test setlerine belirli bir bölümü üzerindeki bağımlılığını azaltmak için, dört yönlü çapraz doğrulama testleri gerçekleştirilmiştir. Yani toplam veriler, dört farklı şekilde eğitim ve test setine bölünmüştür. Gerçek ve tahmin edilen dayanıklılık kaybı arasındaki korelasyon katsayısı elde edilmiştir. Sinir ağı sisteminin, dikiş sonrası ipliklerin mukavemet kaybını iyi bir korelasyon ve daha az ortalama hata ile tahmin edebildiği gözlemlenmiştir. Her bir parametrenin mukavemet kaybının genel tahmine göreceli katkısı, test veri setinin duyarlılık analizi gerçekleştirilerek incelenmiştir. Duyarlılık analizi sonuçları, iplik tipinin en önemli girdi parametresi olduğu ve ardından iplik doğrusal yoğunluğu, kumaş katmanlarının sayısı, kumaş alan yoğunluğu, iğne boyutu ve dikiş yoğunluğunun geldiği görülmüştür.

Rolich ve ark. (2010) çalışmalarında kumaşlara küçük kuvvetlerin yüklenmesi sırasında ortaya çıkan kumaşın uzayabilirliğini araştırmışlardır. Giysi üretim proseslerinin her aşamasında ve giyim eşyalarının kullanımı sırasında kumaş üzerine küçük kuvvetlerin yüklenmesi söz konusudur. Dime dokumalı ve %100 yünden 50 kumaş üzerinde incelemeler yapılmıştır. Kumaşın temel özellikleri olarak çözgü ve atkı yoğunluğu, birim alan ağırlığı, kalınlık girdileri kullanılmıştır. Çözgü ve atkı yönündeki çekme özellikleri KES-FB1 ölçüm sistemi kullanılarak ölçülmüştür. Kumaşların uzayabilirlik özelliklerinin YSA kullanılarak tahmini yapılmış, sonuçlar deneysel değerlerle karşılaştırılıp ve sapmalar belirlenmiştir. Uygulanan araştırmalar sonucu deneysel ve tahmin edilen değerler arasında minimum sapmalar elde edilmiş ve YSA'nın kumaş özelliklerinin tahmininde kullanılabileceği sonucuna varılmıştır.

Bilişik ve Demiryürek (2011), desenli denim kumaşlar geliştirmiş ve bu kumaşların aşınma yükü sonrası mekanik özelliklerini karakterize etmişlerdir. Ayrıca bu kumaşların çekme ve yırtılma mukavemetleri YSA ve istatistiksel model kullanılarak analiz edilmiştir. Tüm denim kumaşlar öncelikle aşındırılmış ve daha sonra aşındırılan kumaşlara ayrı ayrı çekme ve yırtılma testleri uygulanmıştır. Testlerden elde edilen gerçek veriler YSA ve regresyon modeliyle analiz edilmiştir. Regresyon modeli, aşındırılmış büyük yapısal desenli denim kumaşların çekme mukavemeti özelliklerinin, küçük yapısal desenli ve geleneksel denim kumaşlarla karşılaştırıldığında genellikle düşük olduğunu göstermiştir. Öte yandan aşınma çevrimleri arttıkça tüm denim kumaşların çekme özellikleri genel olarak azalmıştır. YSA ve regresyon modellerinden elde edilen sonuçlar ölçülen değerlerle karşılaştırılmıştır. YSA'dan elde edilen değerlerin neredeyse tamamının, regresyon modeliyle karşılaştırıldığında doğru bir şekilde tahmin edildiği sonucuna varılmıştır.

Ünal ve ark. (2012), çalışmalarında süprem örme kumaşların patlama mukavemeti ve hava geçirgenliğinin tahmini için hem regresyon hem de yapay sinir ağı uygulamışlardır. HVI cihazıyla ölçülen lif özellikleri ve iplik özellikleri, santimetre kare başına çubuk ve sıra sayısı ile birlikte bağımsız değişkenler olarak seçilmiştir. İlk olarak altı farklı pamuk türünden, dört farklı iplik numarasında (Ne 20, Ne 25, Ne 30 ve Ne 35) ve üç farklı büküm katsayısında (3.8, 4.2 ve 4.6) konvansiyonel ring iplikler üretilmiştir. Tüm iplikler laboratuvar yuvarlak örgü makinesinde örülmüştür. Kumaş özelliklerini tahmin etmek için regresyon ve YSA modelleri geliştirilmiştir. Süprem kumaş özelliklerinin başarıyla tahmin edilmesinde tüm modellerin kullanılabilirliği bulunmuştur. Ancak YSA modelleri regresyon modellerine göre daha yüksek tahmin gücü sergilemiştir.

Erenler (2013), seçilmiş üretim parametrelerinin bazı kumaş konfor özellikleri üzerine etkisini incelemek ve bu üretim parametrelerinden yola çıkarak kumaş konfor özelliklerinin üretim öncesinde tahmin edilebilmesi için YSA modeli ve YSA ile GA temelli hibrid modeller oluşturulmasını amaçlamıştır. Bu amaca yönelik olarak 81 farklı kumaş üretilmiştir. Kumaş üretiminde çözgü özellikleri ile dokuma şartları sabit tutulmuştur. Bağımsız değişken olarak; atkı ipliğinde 3 farklı elyaf karışım oranı, 3 farklı atkı iplik numarası, 3 farklı atkı sıklığı ve 3 farklı dokuma örgüsü belirlenerek üretim yapılmıştır. Üretilen kumaşlara aynı şartlar altında kasar, optik ağartma ve reaktif boyama işlemi uygulanmıştır. Boyama sonrasında her bir kumaş üzerine 4 farklı apre 3 farklı konsantrasyon ile uygulanarak 972 adet apreli numune elde edilmiştir. Numune kumaşlar üzerinde yumuşaklık, hava geçirgenliği, bağıl su buharı geçirgenliği, nem iletimi, dikey

yönde sıvı iletimi ve buruşmazlık testleri uygulanmıştır. Uygulanan testler sonucunda elde edilen veriler kullanılarak YSA modelleri ve YSA-GA hibrid modelleri kurulmuştur. Sonuç olarak, kurulan YSA modelleri ile kumaş konfor özellikleri, üretim parametreleri kullanılarak tahmin edilebilmiştir. Ayrıca kurulan YSA-GA hibrid modelleri ile de istenilen konfor özelliğine ulaşabilmek için gereken parametre dizileri başarılı bir şekilde tahmin edilebilmiştir.

Kalkancı ve ark. (2017), süprem ve interlok kumaşlardan üretilen tişörtlerin boyutsal ölçüm özelliklerinin YSA aracılığıyla tahmin edilmesi için çalışmışlardır. Bu amaçla, her biri elastanlı ve elastansız olmak üzere 2 gruptan oluşan 2 farklı kumaş grubu altında 72 farklı tipte tişört üretilmiştir. Bu grupların her biri altı farklı malzemenin üç farklı sıklıkta süprem ve interlok olmak üzere iki farklı örgü tekniğiyle üretilmiştir. Bu tişörtlerdeki boyutsal değişimlerin tahmini için ileri beslemeli, geri yayılmalı, momentum öğrenme kuralı ve sigmoid transfer fonksiyonunu içeren modeller kullanılmıştır. Bu çalışmanın sonucunda YSA sisteminin giysilerin kalıp ölçülerini tahmin etmede başarılı olduğu görülmüştür. Sinir ağı modeli tarafından üretilen boyutsal özelliklerin tahmininin oldukça güvenilir olduğu kanıtlanmıştır ($R^2 > 0,99$).

Amor ve ark. (2022), nano titanyum dioksit (TiO_2) kaplı pamuğun çekme mukavemetinin tahmini için YSA kullanmıştır. Kaplama işlemi ultraviyole (UV) radyasyonlarla gerçekleştirilmiştir. Daha sonra çekme mukavemetini tahmin etmek için Bayes düzenleştirmesi ile eğitilmiş bir geri yayımlı YSA algoritması uygulanmıştır. Karşılaştırmalı bir çalışma için YSA sonuçları, çoklu doğrusal regresyon ve polinom regresyon analizi olmak üzere geleneksel yöntemlerle karşılaştırılmıştır. Deney için girdi olarak TiO_2 dozu, UV ışınlama süresi ve sistemin sıcaklığı kullanılmıştır. Simülasyon sonuçları, YSA modelinin geleneksel modellere göre daha yüksek performans doğruluğu sağladığını göstermiştir. Sonuçlar, nano TiO_2 kaplı pamuğun tahmin edilen ve ölçülen gerilme mukavemeti arasında küçük hata değerleriyle güçlü bir korelasyon olduğunu göstermiştir.

Ahirwar ve Behera (2024), polyester pamuk karışım kumaşların çözgü ve atkı bazında çekme mukavemetini tahmin etmek için iki yapay sinir ağı tasarlamışlardır. Kumaş çekme mukavemetini önemli ölçüde etkileyen önemli birkaç girdi parametresinin seçimi için çeşitli süreç ve malzeme ile ilgili parametreler dikkate alınmıştır. Farklı yapılarda toplam 270 kumaş örneği dokunmuştur. Her iki tahmin modelinin eğitimi, test edilmesi ve doğrulanması için doğrusal olmayan modelleme tekniğinin ve kayda değer miktarda veri

setinin uygulanması ile, veriler en iyi şekilde uyarlanmış ve tahmin hatası en aza indirilmiştir. Girdi parametrelerinin katkı yüzdesini belirlemek ve kumaş mukavemetini en çok etkileyen değişkeni değerlendirmek amacıyla her iki model için de duyarlılık analizi yapılmıştır.

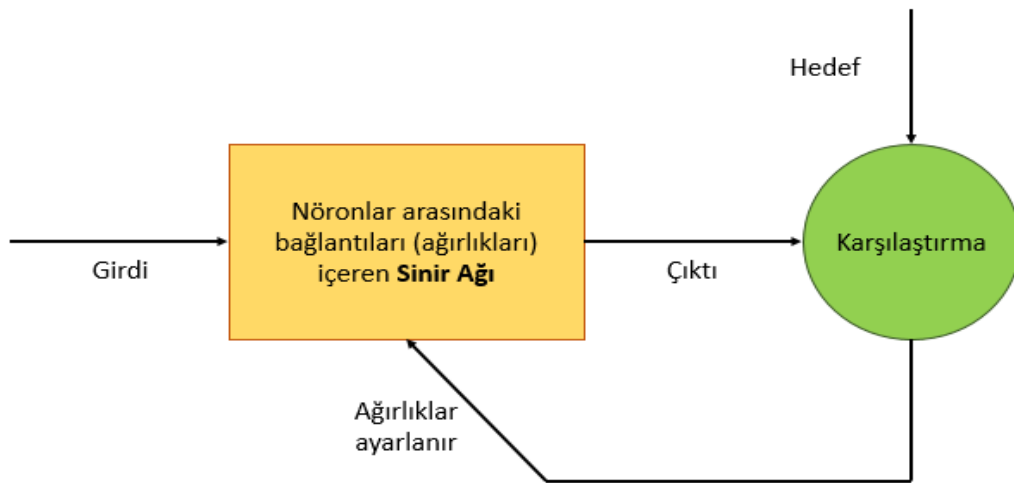


4. YAPAY SİNİR AĞLARI

Yapay sinir ağlarının dayandığı ilk hesaplama modelinin temelleri, 1940'ların başında araştırmalarına başlayan W.S. McCulloch ve W.A. Pitts'in, 1943 yılında yayınladıkları bir makaleyle atılmıştır. Daha sonra 1954 yılında B.G. Farley ve W.A. Clark tarafından bir ağ içerisinde uyarılara tepki veren, uyarılara adapte olabilen model oluşturulmuştur. 1960 yılı ise ilk nöral bilgisayarın ortaya çıkış yılıdır. 1963 yılında basit modellerin ilk eksiklikleri fark edilmiş, ancak başarılı sonuçların alınması 1970 ve 1980'lerde termodinamikteki teorik yapıların doğrusal olmayan ağların geliştirilmesinde kullanılmasına kadar gecikmiştir. 1985 yapay sinir ağlarının oldukça tanındığı, yoğun araştırmaların başladığı yıl olmuştur (Şengöz, 2016).

Yapay sinir ağları, paralel çalışan basit ögelerden oluşmaktadır. Bu ögeler için biyolojik sinir sistemlerinden esinlenilmiştir. Doğada olduğu gibi, ağ işlevi büyük ölçüde ögeler arasındaki bağlantılarla belirlenmektedir. Bir sinir ağı, bu ögeler arasındaki bağlantıların (ağırlıkların) değerlerini ayarlayarak belirli bir işlevi yerine getirmesi için eğitebilmektedir (Beale ve ark., 2018).

Genellikle sinir ağları, belirli bir girdinin belirli bir hedef çıktıya yol açacağı şekilde ayarlanmakta veya eğitilmektedir. Böyle bir durum Şekil 4.1'de gösterilmiştir. Burada, ağ çıktısı hedefle eşleşene kadar, çıktı ve hedefin karşılaştırılmasına dayalı olarak ağ ayarlanmaktadır. Tipik olarak, bu tür birçok girdi/hedef çifti, bu denetimli öğrenmede bir ağı eğitmek için kullanılmaktadır (Beale ve ark., 2018).



Şekil 4.1. Yapay sinir ağı yapısı (Beale ve ark., 2018)

Bir ađın toplu olarak eđitimi, tđm girdi vektörleri setine dayalı olarak ađırlık ve sapma deđişiklikleri yaparak ilerlemektedir. Kademeli eđitim, her bir girdi vektörünün sunumundan sonra bir ađın ađırlıklarını ve sapmalarını gerektiđi gibi deđiştirmektedir. Kademeli eđitime bazen “çevrimiçi” veya “adaptif” eđitim de denilmektedir (Beale ve ark., 2018).

Yapay sinir ađları, örüntü tanıma, tanımlama, sınıflandırma, konuşma, görme ve kontrol sistemleri dahil olmak üzere çeşitli uygulama alanlarında karmaşık işlevleri yerine getirmek üzere eđitilmiştir. İlgili uygulamaların listesi Çizelge 4.1'de verilmiştir. Günümüzde sinir ađları, geleneksel bilgisayarlar veya insanlar için zor olan sorunları çözmek için eđitilebilmektedir (Beale ve ark., 2018).

Çizelge 4.1. Yapay sinir ađı uygulama alanları (Beale ve ark., 2018)

Endüstri dah	Uygulamaları
Havacılık	Yüksek performanslı uçak otopilotu, uçuş yolu simülasyonu, uçak kontrol sistemleri, otopilot geliştirmeleri, uçak bileşen simülasyonu ve uçak bileşen arıza tespiti
Otomotiv	Otomobili otomatik yönlendirme sistemi ve garanti faaliyet analizi
Bankacılık	Çek ve diđer belgeleri okuma ve kredi başvurusu deđerlendirme
Savunma	Silah yönlendirme, hedef izleme, nesne ayrımı, yüz tanıma, yeni tür sensörler, sonar, radar, sinyal/görüntü tanıma ve veri sıkıştırma, özellik çıkarma ve gürültü önleme gibi görüntü sinyali işleme
Elektronik	Kod serisi tahmini, entegre devre çip düzeni, proses kontrolü, çip arızası analizi, yapay görme, ses sentezi ve doğrusal olmayan modelleme
Eđence	Animasyon, özel efektler ve pazar tahmini
Finans	Gayrimenkul deđerlendirmesi, kredi danışmanlığı, ipotek taraması, kurumsal tahvil derecelendirmesi, kredi limiti kullanım analizi, kredi kartı aktivite takibi, portföy alım satım programı, kurumsal finansal analiz ve döviz fiyatı tahmini
Endüstri	Fırınlarda çıkış gazları gibi endüstriyel süreçlerin öngörülmesi, geçmişte kullanılan karmaşık ve maliyetli ekipmanların deđerştirilmesi
Sigorta	Police uygulama deđerlendirmesi ve ürün optimizasyonu
Üretim	Üretim proses kontrolü, ürün tasarımı ve analizi, proses ve makine teşhisi, gerçek zamanlı partikül tanımlama, görsel kalite kontrol sistemleri, kaynak kalite analizi, bilgisayar çipi kalite analizi, kimyasal ürün tasarım analizi, makine bakım analizi, planlama ve yönetim ve kimyasal proses sisteminin dinamik modellemesi
Medikal	Meme kanseri hücre analizi, EEG ve EKG analizi, protez tasarımı, nakil sürelerinin optimizasyonu, hastane giderlerinin azaltılması, hastane kalitesinin iyileştirilmesi ve acil serviste test tavsiyesi
Petrol ve gaz	Keşif
Robotik	Yörünge kontrolü, forklift robotu, manipülatör kontrolörleri ve görüş sistemleri
Menkul kıymetler	Piyasa analizi, otomatik tahvil derecelendirme ve hisse senedi alım satım danışmanlık sistemleri
Konuşma	Konuşma tanıma, sesli harf sınıflandırması ve metinden konuşmaya çevirme
Telekomünikasyon	Görüntü ve veri sıkıştırma, otomatikleştirilmiş bilgi hizmetleri, konuşulan dilin gerçek zamanlı çevirisi ve müşteri ödeme işlemi sistemleri
Taşımacılık	Kamyon fren teşhis sistemleri, araç planlama ve yönlendirme sistemleri

5. DERİN ÖĞRENME

Derin öğrenme, yapay sinir ağları ve insan beyninin işlevlerini taklit eden hesaplama sistemleri kavramına dayanmaktadır. Derin öğrenmenin tarihi, W.S. McCulloch ve W.A. Pitts'in 1943 yılında düşünce sürecini taklit etmek için matematiğe ve sinir mantığı olarak adlandırılan algoritmalara dayalı sinir ağları için bir hesaplama modeli oluşturmalarına uzanmaktadır. Derin öğrenme bir makine öğrenmesi sınıfıdır (URL1, 2024).

Derin öğrenme, özellik çıkarma ve dönüştürme için birçok doğrusal olmayan işlem birimi katmanını kullanmaktadır. Kısaca derin öğrenme, çok katmanlı sinir ağlarına verilen addır. Her ardışık katman, önceki katmandaki çıktıyı girdi olarak kullanır. Algoritmalar denetimli (sınıflandırma gibi) veya denetimsiz (desen analizi gibi) olabilmektedir. Derin öğrenmede, verilerin birden fazla özellik seviyesinin veya temsillerinin öğrenilmesine dayanan bir yapı söz konusudur. Üst düzey özellikler, alt düzey özelliklerden türetilerek hiyerarşik bir temsil oluşturmaktadır. (URL1, 2024).

Derin öğrenme, insanların doğal olarak sahip olduğu deneyimlerden öğrenmeyi, bilgisayarlara yapmayı öğreten bir makine öğrenimi dalıdır. Derin öğrenme, özelliklerin yararlı temsillerini doğrudan verilerden öğrenmek için sinir ağlarını kullanmaktadır. Sinir ağları, paralel olarak çalışan ve biyolojik sinir sistemlerinden ilham alan basit öğeleri kullanarak birden fazla doğrusal olmayan işlem katmanını birleştirmektedir. Derin öğrenme modelleri, nesne sınıflandırmasında bazen insan düzeyindeki performansı aşan en son teknolojiye sahip doğruluk sağlayabilmektedir (Beale ve ark., 2023).

Girdi katmanı ile çıktı katmanı arasındaki katman gizli katmanlardır. Sinir ağları ile derin öğrenme arasındaki fark burada ortaya çıkmaktadır. Temel bir sinir ağı birkaç gizli katmana sahip olabilirken, bir derin öğrenme ağı düzinelerce hatta yüzlerce katmana sahip olabilmektedir. Farklı katman ve düğümlerin sayısını artırmak ağın doğruluğunu artırabilmektedir. Ancak, daha fazla katman bir modelin daha fazla parametre ve hesaplama kaynağı gerektireceği anlamına da gelebilmektedir (URL2, 2024).

Derin öğrenme, ham verileri alan bir dizi girdiye sahip olan sinir ağı katmanları aracılığıyla bilgileri sınıflandırmaktadır. Örneğin, bir sinir ağı kuş görüntüleriyle eğitilirse kuşların görüntülerini tanımak için kullanılabilir. Daha fazla katman, kargayı tavuktan ayırt etmeye kıyasla kargayı kuzgundan ayırt etmek gibi daha kesin sonuçlar sağlayabilmektedir. Derin öğrenme algoritmalarının temelindeki derin sinir ağları, girdi ve çıktı düğümleri arasında birkaç gizli katmana sahiptir, bu da daha karmaşık veri

sınıflandırmalarını gerçekleştirebilecekleri anlamına gelmektedir. Derin öğrenme algoritması ne kadar çok veri alırsa o kadar doğru olmaktadır. Yeni kuş resimlerini doğru bir şekilde sınıflandırmadan önce algoritmanın binlerce kuş resmiyle beslenmesi gerekmektedir (URL2, 2024).

Derin öğrenme uygulamalarında transfer öğrenme yaygın olarak kullanılır. Transfer öğrenmede, önceden eğitilmiş bir ağ, yeni bir görevi öğrenmek için başlangıç noktası olarak kullanılabilir. Transfer öğrenimi ile hazır bir ağda ince ayar yapmak, sıfırdan eğitime göre çok daha hızlı ve kolay olmaktadır. Daha az sayıda eğitim görüntüsü kullanarak ağın yeni bir görevi hızlı bir şekilde öğrenmesi sağlanabilmektedir. Transfer öğreniminin avantajı, önceden eğitilmiş ağın, çok çeşitli diğer benzer görevlere uygulanabilecek zengin bir dizi özellik öğrenmiş olmasıdır. Önceden eğitilmiş bir ağ kullanma ve yeni bir derin ağ oluşturma arasındaki farklar Çizelge 5.1’de özetlenmiştir (Beale ve ark., 2023).

Çizelge 5.1. Önceden eğitilmiş ağ kullanma ile yeni bir derin ağ oluşturma arasında farklar (Beale ve ark., 2023)

	Transfer Öğrenme için Önceden Eğitilmiş Ağ Kullanımı	Yeni Bir Derin Ağ Oluşturma
Eğitim verileri	Yüz ila bin arası veri (küçük)	Bin ila milyon arası veri
Hesaplama	Orta derecede hesaplama (isteğe bağlı GPU)	Yoğun bilgi işlem (hız için GPU gerekli)
Eğitim süresi	Saniye ya da dakika	Gerçek problemler için günler veya haftalar
Model doğrulama	İyi, önceden eğitilmiş modele bağlı	Yüksek, ancak küçük veri kümeleri için numune verileriyle iyi bir uyum, yeni verilerle zayıf uyum

*GPU (Graphics Processing Unit) yani grafik işlemci birimi diye adlandırılan, anakart veya ekran kartı üzerinde bulunan grafik oluşturmakla görevli olan özel bir işlemci birimidir.

5.1. Önceden Eğitilmiş Derin Sinir Ağları

Doğal görüntülerden, güçlü ve bilgilendirici özellikler çıkarmayı zaten öğrenmiş olan önceden eğitilmiş bir görüntü sınıflandırma sinir ağı, yeni bir görev öğrenmek için başlangıç noktası olarak kullanabilmektedir. Bu sinir ağları bir milyondan fazla görüntü üzerinde eğitilmiştir ve görüntüleri klavye, kahve kupası, kalem ve birçok hayvan gibi 1000 nesne kategorisine göre sınıflandırabilmektedir. Transfer öğrenimi ile önceden

eđitilmiş bir sinir ađı kullanmak, bir sinir ađını sıfırdan eđitmekten genellikle çok daha hızlı ve kolaydır (Beale ve ark., 2023).

Önceden eđitilmiş evrişimli sinir ađı (ESA) modelleri olarak da bilinen bu ađlar, genellikle genel bir görüntü tanıma görevi için büyük bir veri kümesi üzerinde eđitilmiş ve başkalarının kullanımına sunulan sinir ađlarıdır. Bu modeller zaten görüntülerdeki çok çeşitli özellikleri ve desenleri tanımayı öğrenmiştir. Önceden eđitilmiş ESA modellerinin önemi, çeşitli bilgisayarlı görme görevleri için güçlü bir temel olarak hizmet edebilme yeteneklerinde yatmaktadır.

Önceden eđitilmiş sinir ađları aşağıdaki görevler için kullanabilmektedir (Beale ve ark., 2023).

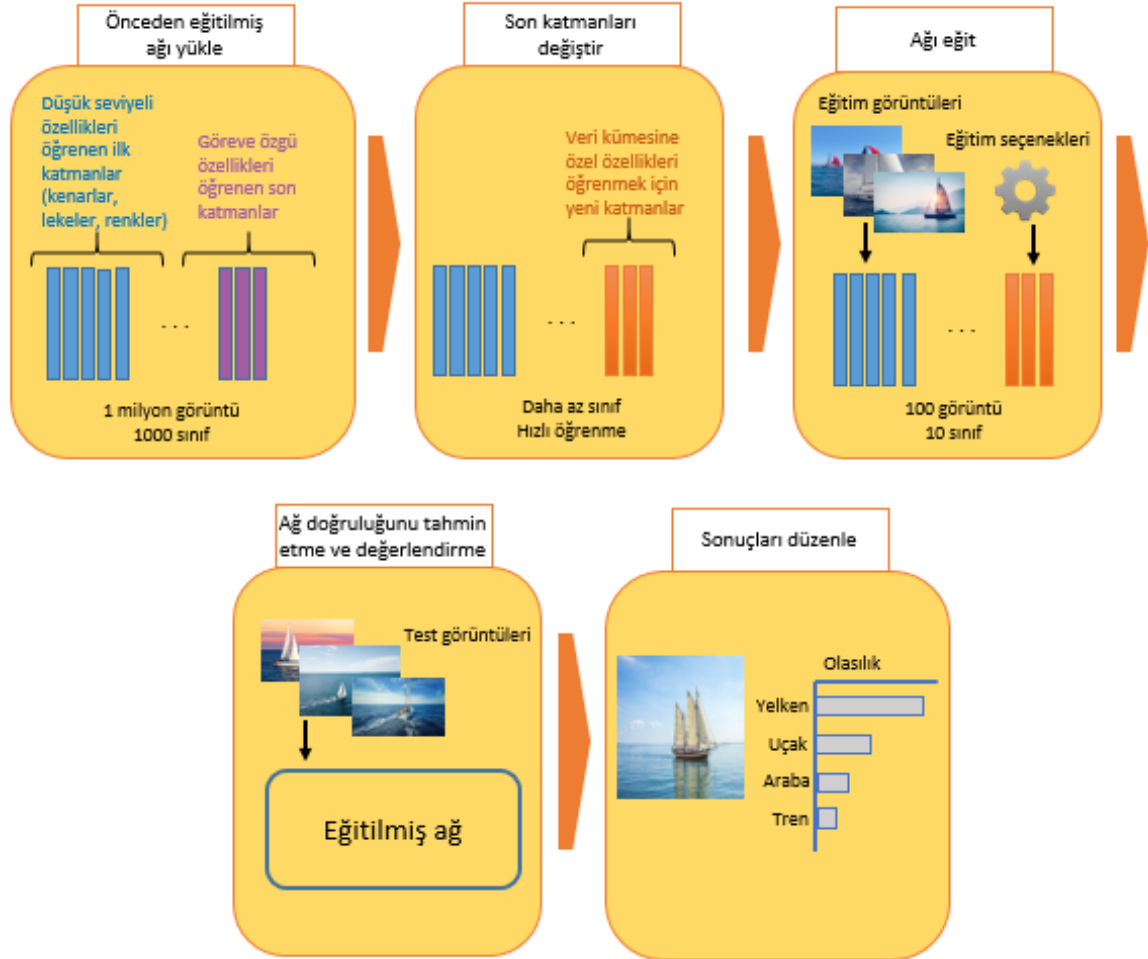
- Sınıflandırma: Yeni bir görüntüyü önceden eđitilmiş sinir ađlarında kullanarak doğrudan sınıflandırma yapmak mümkündür.
- Yüzey özelliđi çıkarma: Katman etkinleştirmelerini özellik olarak kullanarak, önceden eđitilmiş bir sinir ađını özellik çıkarıcı olarak kullanmak mümkün olmaktadır. Bu etkinleştirmeler, destek vektör makinesi gibi başka bir makine öğrenimi modelini eđitmek için özellik olarak kullanabilmektedir.
- Öğrenimi transfer etme: Büyük bir veri kümesi üzerinde eđitilmiş bir sinir ađından alınan katmanlar, yeni bir veri kümesi üzerinde ince ayar yapılarak kullanılabilir.

Önceden eđitilmiş ađlar, geniş bir görüntü yelpazesi için zengin özellikleri içeren temsilleri önceden öğrenmiştir. Bu ađlar, bir görüntüyü girdi olarak almakta ve görüntüdeki nesne için, her bir nesne kategorisine ilişkin olasılıklarla birlikte bir etiket çıkarmaktadır. Önceden eđitilmiş bir ađ alınıp yeni bir görevi öğrenmek için başlangıç noktası olarak kullanılabilir. Bir ađda transfer öğrenimi ile ince ayar yapmak genellikle bir ađı rastgele başlatılan ađlıklarla sıfırdan eđitmekten çok daha hızlı ve kolay olmaktadır (Beale ve ark., 2023).

MATLAB'ta önceden eđitilmiş derin ađların kullanımı için izlenen yol Şekil 5.1'de verilmiştir. Burada ađa verilen bir yelkenli resmini ađın doğru şekilde sınıflandırabilmesi için gerekli işlemler adım adım gösterilmiştir. İlk olarak önceden eđitilmiş ađlardan hangisinin kullanılacağı belirlenmeli ve belirlenen ađ yüklenmelidir. İkinci adımda son katmanlarda deđişiklik yapılarak ađın verimi artırılabilir. Bu deđişiklikler mevcut veri kümesine özgü özellikler nedeniyle gerekli olmaktadır. Üçüncü adımda eğitim görüntüleriyle ađın eğitimi yapılmaktadır. Dördüncü adımda ise kurulan ađın

çalışabilirliğini test etmek için daha önce ağa tanıtılmamış bir yelkenli görüntüsü ağa verilmekte ve son adımda ağın tahmin sonucu bulunmaktadır.

Önceden eğitilmiş derin ağlar olarak kullanılanlardan bazıları şunlardır: squeezeNet, googlenet, densenet, resnet, darknet, alexnet, VGG16 ve VGG19. Bu ağlardan googlenet, alexnet, resnet ve VGG16/VGG19 ile ilgili açıklamalar konu başlıkları ile verilmiştir.




Şekil 5.1. Önceden eğitilmiş derin ağların kullanımı (Beale ve ark., 2023)

5.1.1. GoogLeNet

GoogLeNet, 22 katman derinliğinde evrişimli bir sinir ağıdır. Ağın ImageNet veya Places365 veri kümeleri üzerinde önceden eğitilmiş sürümleri bulunmaktadır. ImageNet üzerinde eğitilen ağ, görüntüleri klavye, fare, kalem ve birçok hayvan gibi 1000 nesne kategorisine göre sınıflandırmaktadır. Places365 üzerinde eğitilen ağ, ImageNet üzerinde eğitilen ağa benzer ancak görüntüleri saha, park, pist ve lobi gibi 365 farklı yer kategorisine göre sınıflandırmaktadır. Bu ağlar, geniş bir görüntü yelpazesi için farklı özellikleri temsil eden görüntüleri öğrenmiştir. Önceden eğitilmiş ağların her ikisi de

224x224 görüntü giriş boyutuna sahiptir (URL3, 2023). Şekil 5.2’de örnek bir GoogLeNet ağ yapısı gösterilmiştir.


Transfer öğrenimi kullanılarak yeni bir görevi gerçekleştirmek için bir GoogLeNet ağı yeniden eğitebilmektedir. Transfer öğrenimini gerçekleştirirken en yaygın yaklaşım, ImageNet veri seti üzerinde önceden eğitilmiş ağları kullanmaktır. Yeni görev nesnelere ziyade yerleri sınıflandırmaya benziyorsa, o zaman Places-365 üzerinde eğitilmiş ağı kullanmak daha yüksek doğruluk sağlayabilmektedir (URL3, 2023).



Şekil 5.2. GoogLeNet ağ mimarisi (Szegedy ve ark., 2014)

5.1.2. AlexNet

AlexNet, 8 katman derinliğinde evrişimli bir sinir ağıdır. ImageNet veritabanından bir milyondan fazla görüntüyle eğitilmiş ağın önceden eğitilmiş bir sürümü yüklenerek kullanılabilir. Önceden eğitilmiş ağ, görüntüleri klavye, fare, kalem ve birçok hayvan gibi 1000 nesne kategorisine göre sınıflandırabilmektedir. Bu ağ, geniş bir görüntü yelpazesi için zengin özellikleri temsil eden görüntüleri öğrenmiştir. Ağın görüntü giriş boyutu 227x227’dir (URL4, 2023). Şekil 5.3’te örnek bir AlexNet ağ yapısı gösterilmiştir.



Şekil 5.3. AlexNet ağ mimarisi (URL5, 2023)

5.1.3. ResNet

ResNet'in orijinal mimarisi 152 katmandan oluşmaktadır. ResNet önceki mimarilere göre daha derin bir yapıya sahiptir. Ağ modelinin derinleşmeye başladığı, öncekilerden farklı bir mantığa sahip olan ResNet, artık değerleri sonraki katmanlara besleyen artık bloğun modele eklenmesiyle oluşturulmaktadır. Bu özelliği ile ResNet klasik bir model olmaktan çıkmaktadır (Çelik ve ark., 2022).


ResNet 152'nin daha küçük bir versiyonu olan ResNet-50, transfer öğrenimi için başlangıç noktası olarak kullanılır. Bu model her biri evrişim ve özdeşlik bloğuna sahip 5 aşamadan oluşur. Her evrişim bloğunda 3 evrişim katmanı bulunur ve her özdeşlik bloğunda ayrıca 3 evrişim katmanı bulunur. ResNet-50'nin 23 milyondan fazla eğitilebilir parametresi vardır (Çelik ve ark., 2022).

5.1.4. VGG16 ve VGG19

VGG16, 16 katman ve VGG19 ise 19 katman derinliğinde evrişimli sinir ağı tasarımlarıdır. VGG kısaltması, Görsel Geometri Grubu anlamına gelmektedir. Önceden eğitilmiş bu ağlar, görüntüleri klavye, fare, kalem ve birçok hayvan gibi 1000 nesne kategorisine göre sınıflandırabilmektedir. Ağların görüntü giriş boyutu 224 x 224'tür. Yenilikçi nesne tanımlama modelleri VGG mimarisi kullanılarak oluşturulmuştur. Derin bir sinir ağı olarak oluşturulan VGG, ImageNet dışındaki çeşitli görevlerde ve veri kümelerinde kıyaslamalarda daha iyi performans göstermektedir. Aynı zamanda günümüzde en sık kullanılan görüntü tanıma mimarilerinden biri olmaya devam etmektedir.

6. ŞÖNİL İPLİK VE ŞÖNİL KUMAŞ

Tesadüfi veya periyodik olarak dağılan düzgünsüzlükleri her türlü formda bünyesinde bulunduran iplik tipine fantezi iplik denir. Bu düzgünsüzlükler renk, büküm, kalınlık, bukle, hav olabilir. Bu düzgünsüzlükler iplik kalınlığını, renk dağılımını değiştirerek veya bunların kombinasyonlarıyla oluşturulmaktadır. Fantezi iplikler özellikleri açısından çok fazla çeşitlilik gösterirler. İpliklerin üretim yöntemlerine, yapısında kullanılan materyal özelliklerine ve kullanım amacına göre değişik özelliklere sahip olmalarına rağmen Şekil 6.1’de görüldüğü gibi temel olarak ana iplik (zemin ipliği), efekt materyal ve bağlama ipliğinden oluşurlar (Çeven ve Şardağ, 2017).




Şekil 6.1. Fantezi ipliğin temel yapısı (Çeven ve Şardağ, 2017)

Ana iplik; fantezi ipliğin temelini oluşturur ve fantezi ipliğin kalitesi ve tutumunu belirlemektedir. Efekt materyal, fantezi iplikteki efekt kısmını oluşturduğundan en önemli bileşendir. Bağlama ipliği ise fantezi ipliğin kalıcılığını ve mukavemetini belirler ve iplik oluşumu sırasında iğ hızına bağlı olarak efekt ve ana ipliğin etrafına sarılarak bu iki ipliği sabitler (Çeven ve Şardağ, 2017).

Fantezi iplik grubu içerisinde yer alan ve özel bir öneme sahip olan bir iplik türü de şönil ipliğidir. Şönil kelimesi Fransızca olup kelime anlamı “tırtıl” veya “tüylü tırtıl” dır. Şönil iplik yumuşak ve tüylü bir yüzeye sahiptir. Şönil iplikler yumuşak tutumları nedeniyle giyim eşyalarında özellikle de örme giyim eşyalarında yaygın olarak kullanılmaktadır. Bu ipliklerin dolgun görünüşleri ise onların dokuma kumaşlarda özellikle de döşemelik kumaşlarda dolgu ipliği olarak kullanılmasını sağlamıştır.

Şönil iplikler temelde iki bileşenden oluşmaktadır. Birinci bileşen bağ iplikleri, ikincisi ise hav iplikleridir (Şekil 6.2). Bağ iplikleri şönil ipliğin merkezinde bulunan ince ve mukavemetli ipliklerdir. Hav iplikleri ise kısa kesilmiş kesikli ya da filament ipliklerden oluşan bileşendir. Hav iplikleri bağ ipliklerinin arasına ardı ardına yerleştirilir ve merkezden dışa doğru belli uzunlukta çıkıntılar oluşturur. Şönil ipliğin yapısında iki tane bağ ipliği vardır. Bu iki bağ ipliği birlikte bükülerek ortalarından geçen hav ipliklerini


tutar. Böylece bağ iplikleri, hav ipliklerini sabitlemiş ve şönil ipliğe mukavemet vermiş olur. Hav iplikleri ise şönil ipliğin hacimli ve kabarık görünmesini ve yumuşak bir tutuma sahip olmasını sağlar (Çeven and Özdemir, 2006; Kavuşturan ve ark., 2010; Alagirusamy and Das, 2015).




Şekil 6.2. Şönil iplik yapısı (Alagirusamy ve Das, 2015; URL6, 2024)

Şönil iplik üretiminde çeşitli doğal ve yapay lifler kullanılabilir. Döşemelik sektöründe kullanılan şönil iplikler genellikle akrilik, viskoz, pamuk ve polyester liflerinden üretilmektedir. Şönil iplik üretiminde polipropilen de yaygın olarak kullanılmaktadır. Bu lifler haricinde bazı çalışmalarda tensel, modal, bambu, soya fasulyesi gibi sürdürülebilir lifler de kullanılmıştır (Kavuşturan ve ark., 2010).

Şönil ipliklerinin üretiminde özel şönil makineleri kullanılır (Şekil 6.3). Genellikle makinenin üretim kısmındaki her bir kafaya 4 bağ ipliği ve 2 hav ipliği beslenir. Şönil iplik makinelerinde 2 iğ için 1 adet kafa ünitesi bulunur (Şekil 6.4). Bağ iplikleri ve hav iplikleri şönil iplik makinesindeki çağlıktan beslenir. Şönil ipliği oluşturacak şekilde bir araya gelerek makinenin alt tarafındaki ring büküm sarım mekanizması sayesinde masuralara sarılır (Erem, 2006).



Şekil 6.3. Şönil iplik makinesi (URL6, 2024)




Şekil 6.4. Şönil iplik makinesi çalışma prensibi (URL6, 2024)

Hav ipliklerinin birim sürede daha fazla sağılmasını sağlamak için hav ve bağ ipliklerinin kafa ünitesine besleme hızları farklıdır. Çağlıktan sağılan bağ iplikleri iplik gerilim düzenleyicilerinden ve iplik kılavuzlarından geçerek kafa ünitesindeki yuvarlak kontrplak

üzerine sarılır. Hav iplikleri ise çağlıktan sonra iplik gerilim düzenleyicileri ve iplik kılavuzlarından sonra makara içine beslenir ve daha sonra kalibre boyunun etrafına sarılır ve kalibre içindeki bıçakta sarılı ipliği kısa uzunluklarda keser (Erem, 2006).

İplik gerilim düzenleyici ve iplik kılavuzları şönil iplikler için çok önemlidir. İplik gerilim düzenleyicinin ayarları bağ ve hav ipliklerinin mukavemetine göre yapılır. Bağ ipliklerinin kafaya eşit gerilim ve hızla girmesi gerekir. Şönil ipliğin numarasını belirleyen parametrelerden biride kalibredir. Kalibrenin boyutları 0,7- 3 mm arasında değişir. Kalibrenin hemen altında döner bıçak bulunur. Bu bıçak kalibreye yüksek hızla sarılan hav ipliklerini ortalayarak keser. İki parçaya kesilen hav ipliği tekerlekler tarafından getirilen temel ipliklerin arasına atılır. Bağ ipliklerinden biri kalibre oyuğundan aşağı inerken, açı yapar. Hav iplikleri bağ ipliklerinin arasına atıldıktan sonra iki bağ ipliği arasındaki açıklık iki bağ ipliğin birbirine bükülmesiyle tamamen kapanır (Erem, 2006).

Şönil iplikler kullanılarak dokunan ya da örülen kumaşlara şönil kumaşlar adı verilir (Şekil 6.5). Şönil kumaşlar ekstra iplikli yapılarda ve güçlendirilmiş kumaş yapılarında dolgu ipliği olarak kullanılır. Şönil kumaşların döşemelik sektöründe tercih edilmesini sağlayan olumlu yönleri olduğu gibi zayıf kaldığı yönleri de vardır. Parlak, kadifemsi ve dolgun görünümleri; havlı yüzeye ve düşük dökümlülüğe sahip olmaları; ekonomik ve üretimlerinin kolay olması (kendisine benzeyen kadife kumaşlara göre üretimleri daha kolaydır) gibi avantajları vardır. Düşük aşınma dayanımı ve kullanım sırasında hav kaybı olması ise dezavantajları arasında yer almaktadır (Erem, 2006).



Şekil 6.5. Şönil iplik ve şönil kumaş görüntüleri (URL6, 2024)

7. MATERYAL VE METOT

Bu çalışma, iki farklı girdi türü kullanılarak şönil kumaşların bazı performans özelliklerini tahminleyebilmek için yapılmıştır. Bu nedenle öncelikle belirlenen özelliklerde şönil iplikler üretilmiş, daha sonra bu iplikler kullanılarak şönil kumaşlar elde edilmiştir. Şönil kumaşlardan görüntüler alınmıştır. Birinci girdi türü olarak, şönil kumaşların belirli iplik ve kumaş özellikleri kullanılmıştır. İkinci girdi türü olarak ise şönil kumaş görüntülerinden çıkarılan yüzey özellikleri kullanılmıştır. Tahminleme aracı olarak YSA modelleri kullanılmıştır. Performans özelliklerinden atkı ve çözgü yönünde kopma mukavemeti ile aşınma direnci tahminlenmeye çalışılmıştır. Çalışmanın detayları sonraki konu başlıklarıyla verilmiştir.


7.1. Materyal

Şönil iplik numunelerinin üretimi için Gaziantep'te bulunan iplik üreticilerinden Melike Tekstil ile çalışılmıştır. Şönil iplik numunelerinin üretiminde polyester, akrilik ve viskon olmak üzere üç farklı hammadde kullanılmıştır. Her bir hammadde için şönil iplikler Nm 1, Nm 2, Nm 4 ve Nm 6 olmak üzere dört farklı numarada üretilmiştir ve bu numaraları sabit tutacak şekilde hav ve bağ iplik numaraları ayarlanmıştır. Her iplik numarası için dört farklı hav uzunluğu kullanılmıştır. Bu şekilde 48 farklı iplik numunesi elde edilmiştir. İpliklerin üretiminde kullanılan hav ve bağ iplik çeşitleri ile bahsi geçen bilgiler Çizelge 7.1'de özetlenmiştir.

Üretilen iplik numunelerinden dokuma kumaş üretimi için Kahramanmaraş'ta bulunan Kipaş Holding firmasından destek alınmıştır. CCI TECH INC. numune dokuma tezgahı kumaş üretiminde kullanılmıştır. Atkı ipliği olarak şönil iplik numuneleri ve çözgü ipliği olarak ise 150/36 (150 denye/36 filamentli) polyester iplik kullanılmıştır. Kumaş konstrüksiyonu 8/8 atkı ripsi (kenarlar 2/2 çözgü ripsi) ve tarak numarası 155/4 olacak şekilde üretim gerçekleştirilmiştir (çözgü sıklığı 62 tel/cm olarak sabit tutulmuştur). Kumaş atkı sıklığı her kumaş için örtme faktörü aynı olacak şekilde ayarlanmıştır. Kumaşların kalınlık ölçümleri için SCHMIDT kalınlık ölçer cihazı (Şekil 7.1a) ve gramaj ölçümleri için AXIS AGN220 elektronik hassas terazi (Şekil 7.1b) kullanılmıştır. Kumaş kalınlık ölçümleri TS 7128 EN ISO 5084 standardına ve kumaş gramaj ölçümleri TS EN 12127 standardına göre yapılmıştır. Üretilen kumaşla ilgili olarak, atkı sıklığı, gramaj ve kalınlık değerleri Çizelge 7.1'de verilmiştir.

Çizelge 7.1. Üretilen şönil iplik ve şönil kumaş özellikleri

Numune no	Bağ ipliği	Hav ipliği	İplik numarası (Nm)	Hav uzunluğu (mm)	Atkı sıklığı (tel/cm)	Ağırlık (gr/m ²)	Kalınlık (mm)
1	20/1 PES	150/144 PES	1	3	4	561.85	2.64
2	20/1 PES	150/144 PES	1	4	4	591.62	2.61
3	20/1 PES	150/144 PES	1	5	4	479.19	2.55
4	20/1 PES	150/144 PES	1	6	4	496.37	2.96
5	20/1 PES	150/144 PES	2	1.5	5	453.82	2.10
6	20/1 PES	150/144 PES	2	2	5	357.07	1.73
7	20/1 PES	150/144 PES	2	3	5	359.11	1.87
8	20/1 PES	150/144 PES	2	4	5	395.16	2.32
9	20/1 PES	150/144 PES	4	0.8	10	376.37	1.33
10	20/1 PES	150/144 PES	4	1	10	423.37	1.62
11	20/1 PES	150/144 PES	4	1.5	10	348.91	1.49
12	20/1 PES	150/144 PES	4	2	10	427.15	2.09
13	20/1 PES	150/144 PES	6	0.8	14.5	408.58	1.46
14	20/1 PES	150/144 PES	6	1.2	14.5	411.45	1.71
15	20/1 PES	150/144 PES	6	1.5	14.5	397.50	1.80
16	20/1 PES	150/144 PES	6	2	14.5	389.27	1.85
17	16/1 akrilik	20/1 akrilik	1	3	4	692.72	3.16
18	16/1 akrilik	20/1 akrilik	1	4	4	575.41	3.09
19	16/1 akrilik	20/1 akrilik	1	5	4	539.11	2.94
20	16/1 akrilik	20/1 akrilik	1	6	4	494.09	2.67
21	16/1 akrilik	20/1 akrilik	2	1.5	5	351.96	1.89
22	16/1 akrilik	20/1 akrilik	2	2	5	426.23	2.39
23	16/1 akrilik	20/1 akrilik	2	3	5	392.56	2.41
24	16/1 akrilik	20/1 akrilik	2	4	5	363.29	2.38
25	20/1 akrilik	20/1 akrilik	4	0.8	10	405.05	2.06
26	20/1 akrilik	20/1 akrilik	4	1	10	351.45	1.74
27	20/1 akrilik	20/1 akrilik	4	1.5	10	339.43	1.69
28	20/1 akrilik	20/1 akrilik	4	2	10	355.93	1.83
29	24/1 akrilik	24/1 akrilik	6	0.8	14.5	361.69	1.69
30	24/1 akrilik	24/1 akrilik	6	1.2	14.5	401.47	2.06
31	24/1 akrilik	24/1 akrilik	6	1.5	14.5	386.08	2.23
32	24/1 akrilik	24/1 akrilik	6	2	14.5	371.36	2.40
33	28/1 viskon	28/1 viskon	1	3	5	532.96	2.40
34	28/1 viskon	28/1 viskon	1	4	6.5	634.21	3.05
35	28/1 viskon	28/1 viskon	1	5	6.5	781.00	3.53
36	28/1 viskon	28/1 viskon	1	6	6.5	774.51	3.63
37	28/1 viskon	28/1 viskon	2	1.5	5	384.74	1.99
38	28/1 viskon	28/1 viskon	2	2	5	328.54	1.59
39	28/1 viskon	28/1 viskon	2	3	6	368.21	2.05
40	28/1 viskon	28/1 viskon	2	4	6	416.67	2.41
41	28/1 viskon	28/1 viskon	4	0.8	10	406.39	1.61
42	28/1 viskon	28/1 viskon	4	1	10	401.84	1.59
43	28/1 viskon	28/1 viskon	4	1.5	10	360.57	1.72
44	28/1 viskon	28/1 viskon	4	2	10	357.92	1.76
45	28/1 viskon	28/1 viskon	6	0.8	14.5	419.87	1.83
46	28/1 viskon	28/1 viskon	6	1.2	14.5	377.43	1.63
47	28/1 viskon	28/1 viskon	6	1.5	14.5	368.04	1.70
48	28/1 viskon	28/1 viskon	6	2	14.5	339.76	2.04



Şekil 7.1. Şönil kumaşların a) kalınlık ve b) gramaj ölçümleri

7.2. Metot

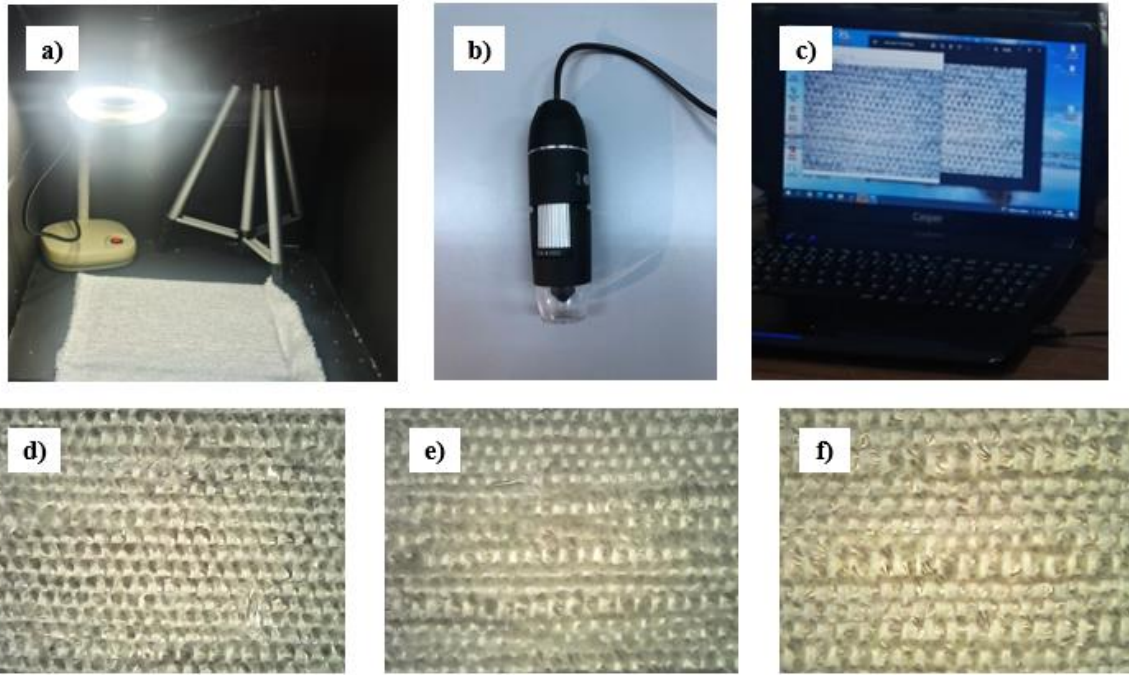
7.2.1. Performans testleri

Üretilen dokuma kumaşların, kopma mukavemeti ve aşınma direnci ölçümleri için de Kipaş Holding firmasından destek alınmıştır. Atkı ve çözgü yönünde kopma mukavemeti testi ISO 13934-1 standardına göre James Heal Titan² Universal Strength Tester ile ve aşınma direnci testi ISO 12947-2 standardına göre James Heal Martindale Abrasion and Pilling Tester ile yapılmıştır. Kopma mukavemeti testleri için 60 mm eninde ve 350 mm boyunda kumaş numuneleri alınmıştır. Kumaş kenarlarının her iki tarafından 5 mm'lik saçaklandırma yapılmıştır. Cihaz çeneleri arasındaki mesafe 200 mm'ye ayarlanarak test gerçekleştirilmiştir. Ölçümlerde maksimum kuvvet (Newton cinsinden) dikkate alınmıştır. Her farklı kumaş için atkı ve çözgü yönünde 5'er numune test edilmiş ve test sonuçlarının ortalaması alınmıştır. Aşınma direnci testleri için 38 mm çapında numuneler kullanılmıştır. Ayrıca 140 mm çapında standart aşındırma kumaşı kullanılmıştır. 12 kPa ağırlıklarla test uygulanmıştır. Kumaş numunesinde kopma meydana gelinceye kadar teste devam edilmiş olup, kopmanın meydana geldiği tur sayıları kaydedilmiştir. Her farklı kumaş için 3'er numune test edilmiş ve elde edilen değerlerin ortalaması alınmıştır.

7.2.2. Görüntü alma sistemi

Şönil kumaşların yüzey özelliklerinden performans özelliklerinin tahmin edileceği ağırlık eğitilmesi amacı ile kumaş görüntüsünden yüzey özelliklerinin çıkarılması gerekmektedir.

Kumaş görüntülerinin alınması amacı ile görüntü alma sistemi kurulmuştur. Bu sistem, kabin, mikroskop kamera ve aydınlatma ünitesinden oluşmaktadır. Çalışmamızın amacına uygun olarak şönil kumaşlardan görüntü alabilmek için Gaziantep Üniversitesi'nde bulunan ışıklı bir kabin kullanılmıştır. Işıklandırma olarak öncelikle kabinde yer alan ledli ışıklandırma denenmiş ancak bu ışıklandırma ile istenilen netlikte görüntüler alınmadığı için floresan lamba ışıklandırma için kullanılmıştır (Şekil 7.2a). Görüntüler, 1000x'e kadar büyütebilen bir mikroskop kamerası ile 640x480 piksel ve 96dpi özelliklerinde alınmıştır (Şekil 7.2b). Mikroskop kamera tripota yerleştirilerek kumaş üzerine konumlandırılmıştır. Her bir numune için farklı bölgelerinden olmak üzere 10 görüntü alınmıştır. Görüntülerin bilgisayara aktarımında, web kameradan video kaydı ve görüntü yakalamayı sağlayan AMCap programı kullanılmıştır (Şekil 7.2c). İplik numarası Nm 1 ve hav uzunluğu 3 mm olan ipliklerden elde edilen polyester, akrilik ve viskon kumaş numunelerine ait görüntüler Şekil 7.2d,e,f'de verilmiştir.



Şekil 7.2. Şönil kumaşlardan görüntü alma a) ışıklandırılmış kabin düzeneği b) AMCap programı c) mikroskop kamera d) polyester kumaş e) akrilik kumaş f) viskon kumaş

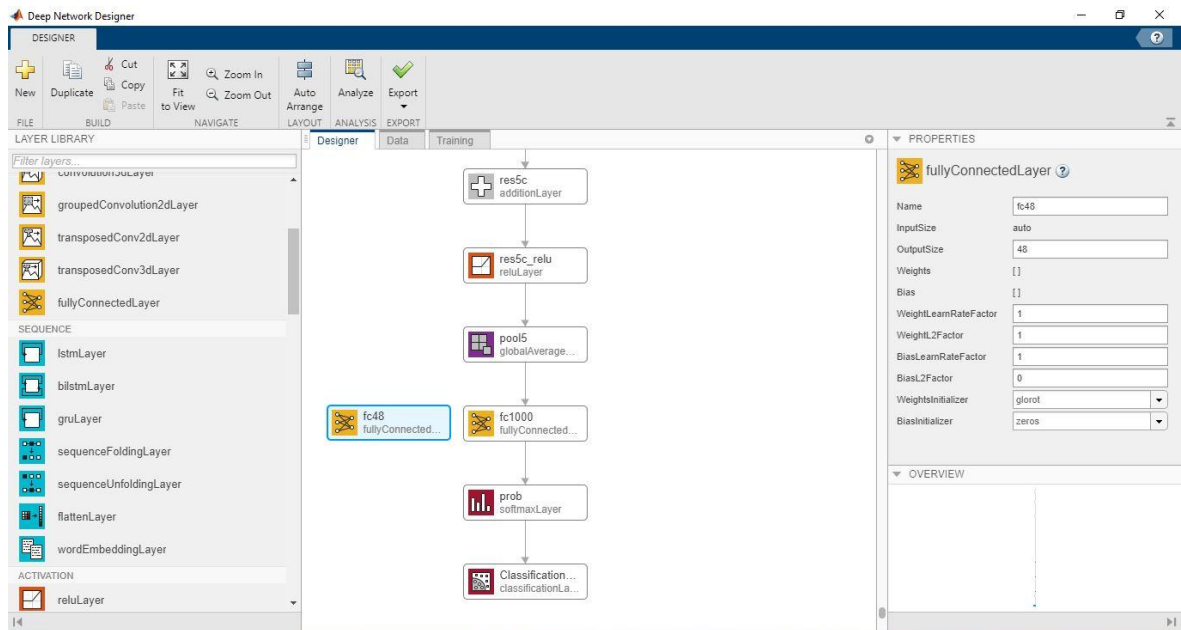
7.2.3. MATLAB derin öğrenme ağ düzenlemesi

MATLAB'ta "Deep Network Designer" araç kutusunda önceden eğitilmiş derin sinir ağları bulunmaktadır. Bu ağlar daha önceden de bahsedildiği gibi sıfırdan bir ağ kurmak yerine mevcut ağlar üzerinde çeşitli değişiklikler yaparak problemlerin çözümünde zamandan tasarruf ve kolaylık sağlamaktadır. Bu çalışma için önceden eğitilmiş çeşitli sinir ağları

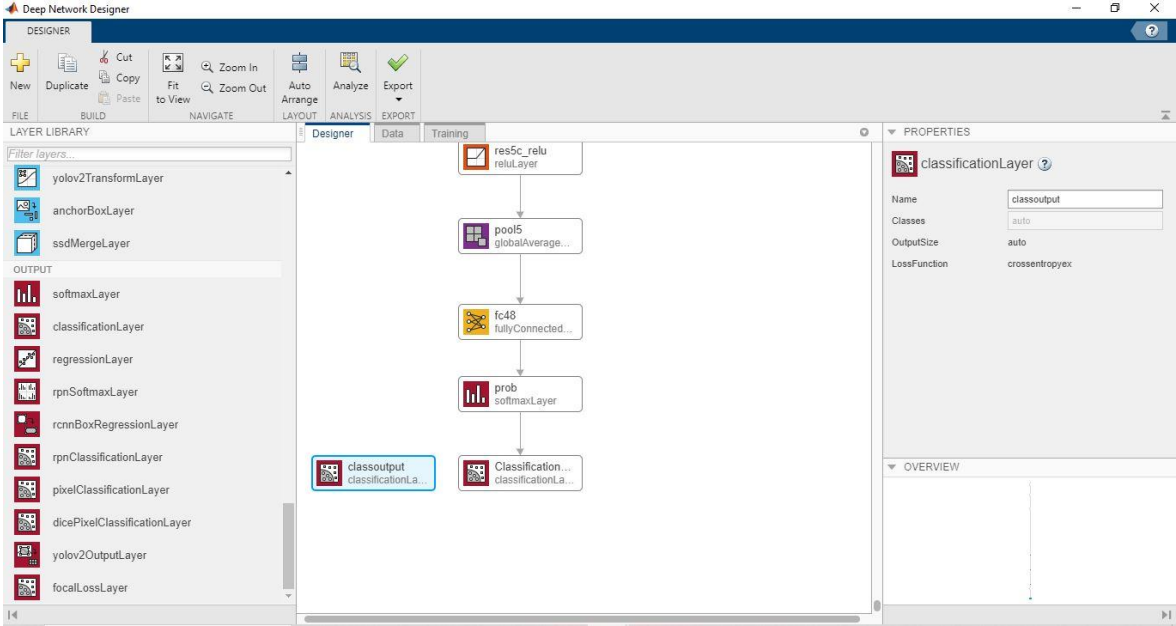
modifiye edilerek denemeler yapılmıştır. Kullanılan ağlar şunlardır: googlenet, resnet101, vgg16, vgg19 ve alexnet. Ağların hepsi aynı adımlar izlenerek modifiye edilmiştir. Bu nedenle sonraki açıklamalarda sadece resnet101 ağının modifiye edilme adımları verilmiştir.

Önceden eğitilmiş resnet101 ağının, kendi verilerimize uyarlayabilmek için modifiye edilmesi gerekmektedir. Öncelikle MATLAB 2020a versiyonunda “Deep Network Designer” araç kutusu açılmıştır. Açılan araç kutusunda resnet101 ağı seçilmiştir. Karşımıza gelen ekranda “designer”, “data” ve “training” olmak üzere üç kısım görülmektedir. Bu kısımlara tek tek gelerek çalışmamıza uygun ayarlamalar yapılmıştır.

İlk olarak “designer” kısmı ile başlanmıştır. Bu kısımda ağın katmanlı tasarımı görülmektedir. Ağın çalışmamıza uygun olarak modifiye edilebilmesi için bazı katmanlarda değişiklikler yapılmıştır. Bunun için en son katmanlara gidilmiştir. Burada bulunan “fully connected” katmanının değiştirilmesi gerekmektedir. Bu değişim kendi numunelerimize ait sınıf sayısı ile alakalıdır. 48 numunenin her birinden 10’ar tane görüntü alınmıştır, yani toplam 480 görüntü bulunmaktadır. Sınıf sayısının 48 olarak alınması gerekmektedir. Eski fully connected katmanı silinmiştir. Yeni eklenen fully connected katmanında “outputsize” 48 olarak değiştirilmiş ve bu katman “fc48” olarak adlandırılmıştır (Şekil 7.3). Son katman olan “classification” katmanının da değiştirilmesi gerekmektedir. Mevcut katman silinerek yeni classification katmanı eklenmiştir ve yeni katmanda herhangi bir değişiklik yapılmamıştır (Şekil 7.4).

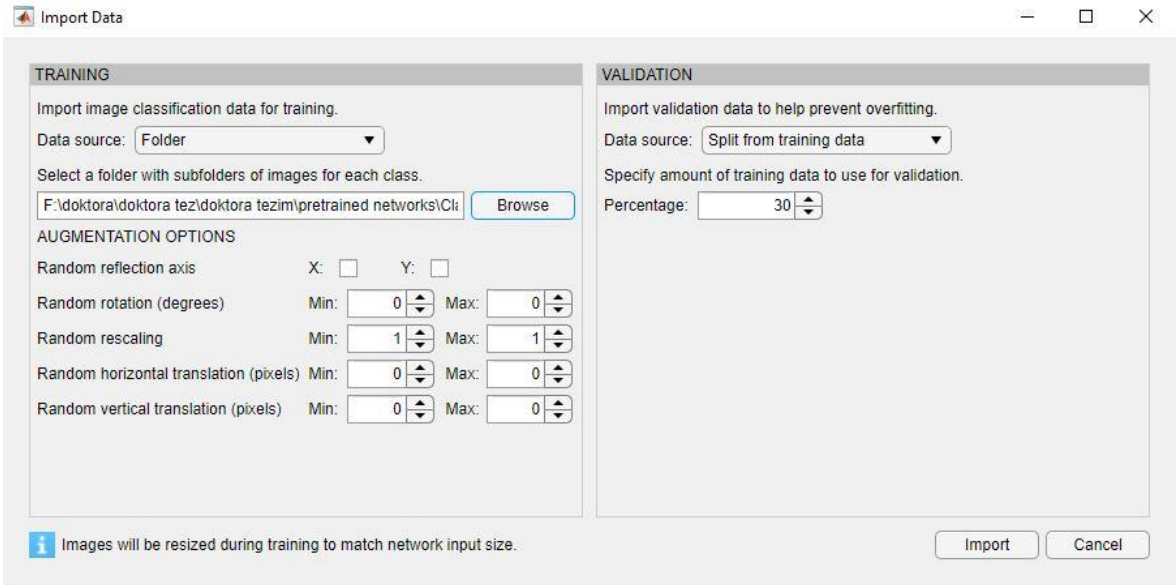


Şekil 7.3. Resnet101 ağında “fully connected” katmanını değiştirme

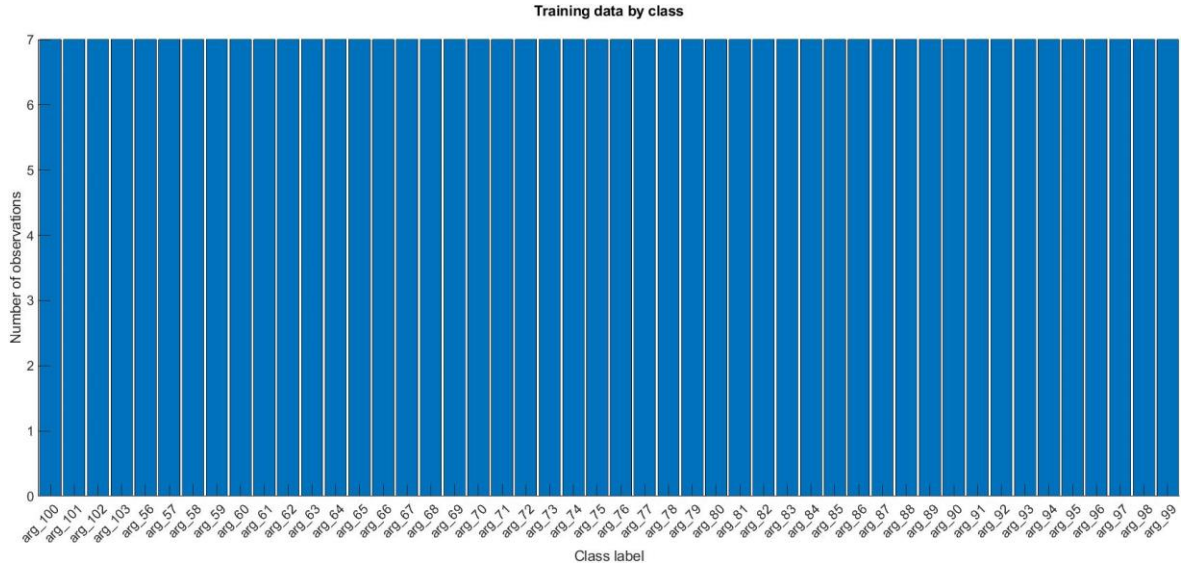


Şekil 7.4. Resnet101 ağında “classification” katmanını değiştirme

Bu işlemlerden sonra “data” sekmesine gelinmiştir. Bu ekranda “import data” seçeneği ile verilerin seçilmesi gerekmektedir. “ClassName” isimli daha önceden oluşturulmuş dosya seçilir. Bu dosyada 48 sınıfa (numuneye) ait 48 alt dosya bulunmaktadır. Her bir alt dosyada bir numune için 10 görüntü bulunmaktadır. Seçilen görüntüler üzerinde ağın nasıl çalışacağını belirlemek için “augmentation options” kısmından rastgele döndürme ve rastgele ölçeklendirme gibi ayarlar yapılabilmektedir (Şekil 7.5). Verileri girdikten sonra, dataların sınıflandırıldığı Şekil 7.6’daki görüntü ekrana gelmektedir.



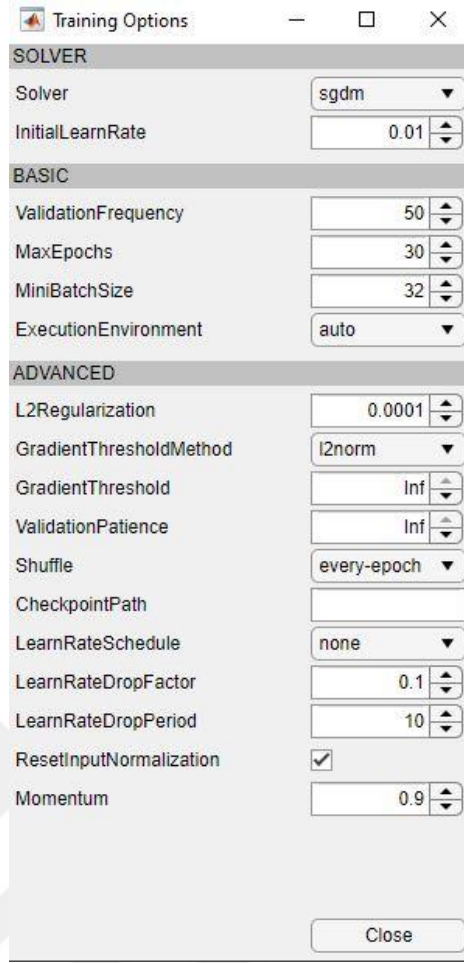
Şekil 7.5. Resnet101 ağında veri ekleme



Şekil 7.6. Resnet101 ağında verilerin sınıflandırılması

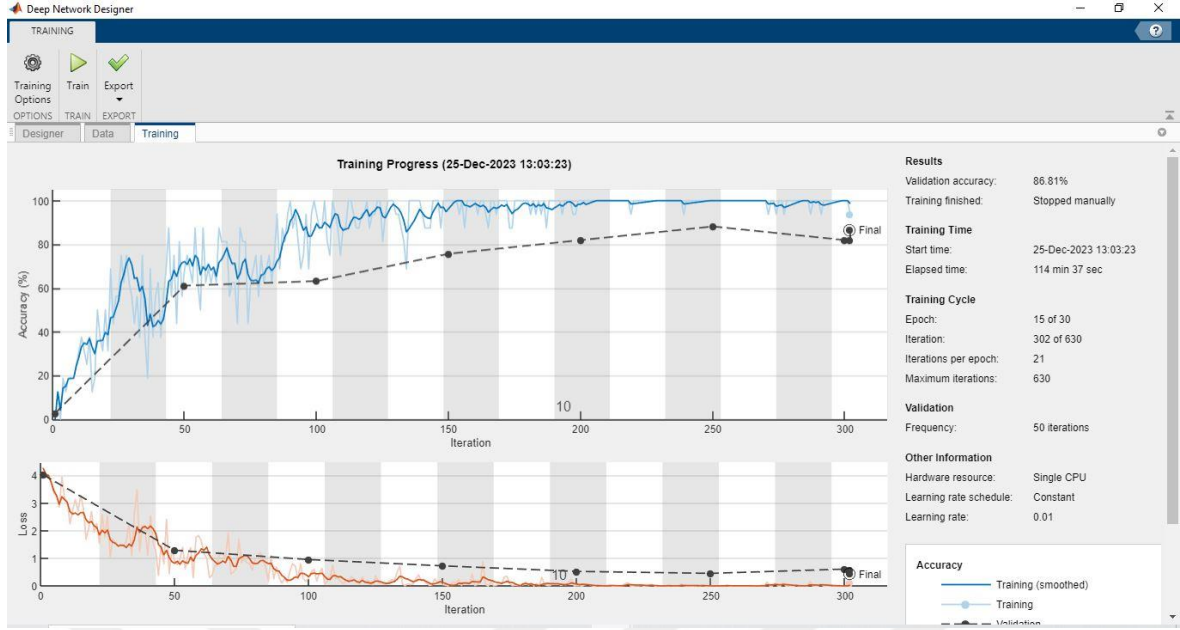
Daha sonra “training” sekmesine gelinmiş, training options kısmından eğitilecek ağı ile ilgili ayarlar girilmiştir. Bu kısımda bütün parametreler varsayılan (default) değerleri ile birlikte ekrana gelmektedir. “Minibatchsize” parametresi hariç bütün parametreler için varsayılan değerler kullanılmıştır. Minibatchsize için 128 olan varsayılan değer yerine 32 girilmiştir (Şekil 7.7).

Derin öğrenme uygulamalarında, veri setinde bulunan tüm verileri aynı anda işleyerek öğrenme, zaman ve bellek açısından maliyetli bir iştir. Çünkü öğrenmenin her iterasyonunda geriye yayılım (backpropagation) işlemi ile ağı üzerinde geriye dönük olarak gradyan (gradient descent) hesaplaması yapılmakta ve ağırlık değerleri bu şekilde güncellenmektedir. Hesaplama işleminde veri sayısı ne kadar fazla ise hesaplama da o oranda fazla sürmektedir. Bu problemi çözmek için; veri seti küçük gruplara ayrılmakta ve öğrenme işlemi seçilen bu küçük gruplar üzerinde yapılmaktadır. Bu şekilde birden fazla girdinin parçalar halinde işlenmesi “minibatch” olarak adlandırılmaktadır. Model tasarlanırken minibatch parametresi olarak belirlenen değer; modelin aynı anda kaç veriyi işleyeceği anlamına gelmektedir (URL7, 2024).



Şekil 7.7. Resnet101 ağında eğitim seçenekleri

Buraya kadar yapılan işlemlerle hem resnet101 ağı kendi verilerimize uygun olarak modifiye edilmiş hem de ağı ile ilgili ayarlar yapılmıştır. Daha sonra “train” seçeneği ile ağına eğitime geçilmiştir. Ağına eğitiminin nasıl ilerlediğine dair “training progress” grafiği eğitim boyunca görülmektedir. Eğitim tamamlandıktan sonra grafik ve eğitime dair bilgiler Şekil 7.8’de görülmektedir. Ağına doğrulama başarısı %86.81 olarak bulunmuştur.



Şekil 7.8. Modifiye Resnet101 ağının eğitim grafiği

Kullanılan derin sinir ağlarının hepsini resnet101 ağı gibi modifiye ettikten sonra elde edilen doğrulama başarıları Çizelge 7.2’de görülmektedir.

Çizelge 7.2. Modifiye edilmiş derin sinir ağları sonuç tablosu

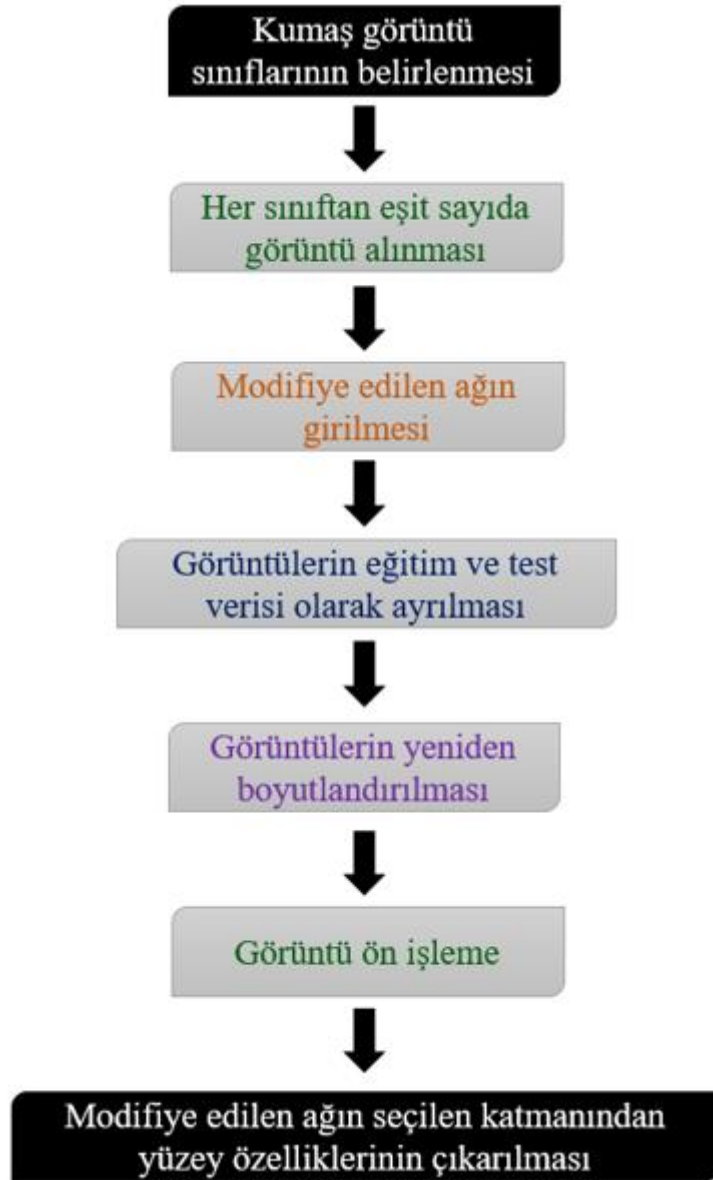
DERİN SİNİR AĞI	TEST DOĞRULUĞU (%)
googlenet	8.33
resnet101	86.81
vgg16	2.08
vgg19	2.08
alexnet	2.08

Sonuçlardan da görüldüğü üzere resnet101 ağı haricindeki ağlar başarısız bir tablo sergilemiştir. Mevcut görüntülerden yüzey özelliklerinin çıkarılması için başarı oranı yüksek olan resnet101 ağı seçilerek çalışmanın sonraki aşamalarına devam edilmiştir.

7.2.4. Yüzey özelliklerinin çıkarılması

Bu kısımda modifiye edilmiş resnet101 ağı ile şönil kumaş görüntülerinden özellik çıkarma işlemi yapılmıştır. Bu işlem için de 48 numuneye ait 480 adet görüntünün olduğu “Classname” isimli dosya kullanılmıştır. Bu dosyadaki görüntüler katagorize edilmiş (48

sınıfa ayrılmış) ve görüntü veri deposu (image data store) oluşturulmuştur. Sonra her numuneden eşit sayıda görüntü alınması işlemi gerçekleştirilmiştir. Modifiye ettiğimiz resnet101 ağı girilerek işlemlere devam edilmiştir. Görüntüler eğitim ve test verisi olarak ayrılıp, görüntü boyutları ağı uygun hale getirilmiştir. Gri tonlamalı görüntüler, RGB (R-red-kırmızı, G-green-yeşil, B-blue-mavi) renk modeline dönüştürülmüştür. Modifiye edilmiş resnet101 ağının fc48 katmanından özellik çıkarma işlemi gerçekleştirilmiştir. Şekil 7.9’da yüzey özelliği çıkarma ile ilgili akış diyagramı verilmiştir.



Şekil 7.9. Yüzey özelliği çıkarma akış diyagramı

7.2.5. Değerlendirmelerde kullanılan istatistiksel araçlar

Çalışmada yer alan deneysel verilerin ve tahminlenen değerlerin karşılaştırmasını yapabilmek için ortalama mutlak yüzdesel hatası, R ve R² değerleri gibi çeşitli istatistiksel araçlar kullanılmıştır.

Ortalama mutlak yüzdesel hatası (OMYH), veri setindeki gerçek değerler ile tahminlenen değerler arasındaki mutlak farkların gerçek değerlere yüzde oranlarının toplamının örnek sayısına bölünmesiyle elde edilen sonucun yüzdesi olarak hesaplanmaktadır. Değer ne kadar düşükse o kadar iyi performans elde edilir. OMYH'nin hesaplanması için aşağıdaki formüller kullanılmıştır:

$$Hata (\%) = \frac{|x_i - y_i|}{y_i} \times 100 \quad (7.1)$$

$$OMYH = \frac{\sum_{i=1}^n \left| \frac{x_i - y_i}{y_i} \right| \times 100}{n} \quad (7.2)$$

burada i test numunesini, n toplam test numunesi sayısını, y_i test sonucundan elde edilen gerçek değerleri, x_i her test numunesi için tahmini değerleri göstermektedir. OMYH'nin değerlendirilmesi ise literatürde Çizelge 7.3'e göre yapılmaktadır.

Çizelge 7.3. OMYH değerlerinin yorumlanması (Lewis, 1982; Montaño Moreno ve ark., 2013)

OMYH değer aralığı	Değerlendirme
<10	Yüksek doğrulukla tahminleme
10-20	İyi tahminleme
20-50	Makul derecede tahminleme
>50	Yanlış tahminleme

Doğrusal regresyon sonucu bulunan R (korelasyon katsayısı) değeri ise, veri setindeki gerçek değerler ile tahminlenen değerler arasındaki ilişkinin gücünü açıklamak için kullanılmıştır. R değerinin bulunmasında kullanılan formül aşağıdaki denklemde verilmiştir. R, -1 ila 1 arası değerler alır.

$$R = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (7.3)$$

Burada, y_i test sonucundan elde edilen gerçek değerleri ve \bar{y} bu değerlerin ortalamasını, x_i her test numunesi için tahmini değerleri ve \bar{x} bu değerlerin ortalamasını göstermektedir.

Verilen denkleme göre gerçek ve tahminlenen değerler arasındaki ilişki, doğrusal eğri ve noktalardan oluşan bir grafikte gösterilebilmektedir. Eğer doğrusal eğri, grafik üzerindeki tüm noktalardan geçiyorsa, $R=1$ olur. Bu durumda, açıklanabilen varyasyon, açıklanamayan varyasyona eşittir. Grafik üzerindeki noktalar doğrusal eğri üzerinden sapıyorsa, bu defa açıklanmayan varyasyon daha büyük olacak ve $R<1$ olacaktır. Regresyon analizinde hesaplanan korelasyon katsayısı ile, iki değişken arasındaki ilişkinin var olup olmadığı test edilir. Bu ilişkinin yönü (artan veya azalan) ve gücü ölçülmüş olur. Bu noktada Evans (1996)'ın çeşitli büyüklük sınıflandırmaları ve yorumları bulunmaktadır: $<0,20$ korelasyonlar çok zayıf, $0,20-0,39$ arasındaki korelasyonlar zayıf, $0,40-0,59$ arasındaki korelasyonlar orta derecede, $0,60-0,79$ arasındaki korelasyonlar güçlü ve $>0,80$ korelasyonlar ise çok güçlü. Ancak bu tür sınıflandırmaların dikkatli kullanılması veya kaçınılması ve korelasyon katsayılarının yorumunun konu alanına özel olması gerektiği de belirtilmektedir (Papageorgiou, 2022).

R^2 (determinasyon katsayısı) ise regresyon analizinde deneysel verilerin doğrusal bir eğriye ne kadar iyi uyduğunun en iyi ölçütüdür. R^2 değerinin bulunmasında kullanılan formül aşağıdaki denklemde verilmiştir.

$$R^2 = 1 - \sum \frac{(y_i - x_i)^2}{(y_i - \bar{y})^2} \quad (7.4)$$

Burada, y_i test sonucu elde edilen gerçek değerleri ve \bar{y} bu değerlerin ortalamasını, x_i her test numunesi için tahmini değerleri göstermektedir. $R^2 = 1$ olması, deneysel verilerin kusursuz bir doğrusal eğri sağlandığının kanıtıdır.

7.2.6. Yapay sinir ağı (YSA) tasarımı

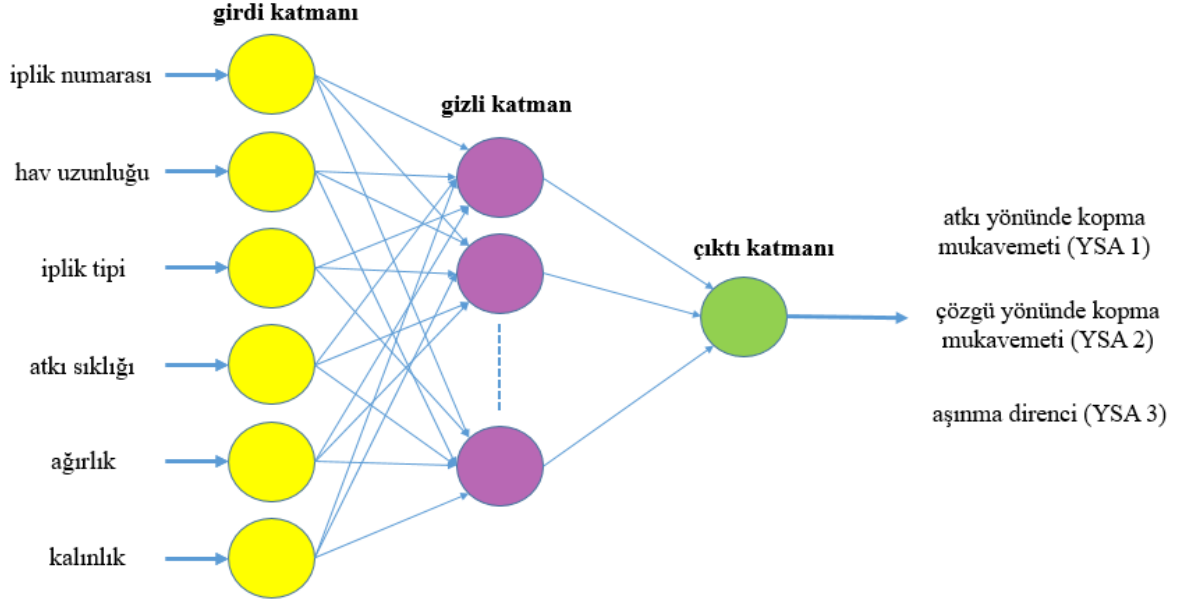
7.2.6.1. İplik ve kumaş verilerini kullanarak tahminleme için YSA modelleri

YSA modelleri, doğrusal olmayan ve karmaşık sistemlerin işleyişini simüle etmek için kullanılacak bir bilgi sürecidir. YSA'nın yapısı, girdi katmanı, gizli katman ve çıktı katmanı olmak üzere farklı katmanlardan oluşabilmektedir. Girdi katmanı girdi sinyallerini

alır ve dağıtır. Gizli katmanlarda girdi ve çıktı katmanları arasında ilişki oluşturulur ve çıktı katmanı çıkış değerini verir. Mevcut veriler üç gruba ayrılmıştır: eğitim, doğrulama ve test verileri. Birinci grup, ağ ağırlıklarının ve sapmalarının hesaplanması ve güncellenmesi için kullanılan eğitim setidir. İkinci grup, ağ aşırı uyum sağlamaya başladığında kullanışlıdır, dolayısıyla doğrulama kümesindeki hata genellikle artar. Bu noktada, minimum doğrulama hatasındaki ağırlıklar ve sapmalar geri döndürülür. Doğrulama setindeki hata, eğitim süreci boyunca izlenir. Doğrulama setindeki hata arttığında eğitim durdurulur. Son grup ise elde edilen YSA'nın test aşamasında değerlendirilmesi için kullanılır. Test seti hatası eğitim sırasında kullanılmaz (Moezzi ve ark., 2015).

Literatürde ağ tasarımları için çeşitli öneriler sunulmuştur. Gizli katmanlardaki nöron sayısını belirlemek için çeşitli kurallar önerilmiştir. Bunlar arasında “ $2n+1$ ”, “ $2n$ ”, “ n ”, “ $n/2$ ” yer almaktadır; n , girdi değişkenlerinin sayısıdır (Hecht-Nielsen, 1990; Lippmann, 1987; Wong, 1991; Tang& Fishwick, 1993; Kang, 1991). Bulunan bu kurallara rağmen, hiçbiri incelenen problem için iyi sonuç vermeyebilir; bu nedenle burada tamamen ampirik yaklaşım gerekmektedir. Çıktı değişkenlerinde ise, bir ağın aynı anda birkaç görev için eğitilmesi genellikle tavsiye edilmemektedir (Almetwally ve ark., 2014).

Bu çalışmada MATLAB 2020a versiyonunda sinir ağı araç kutusu kullanılmıştır. Model oluşturmak için altı adet girdi verisi kullanılarak, üç adet çıkış verisini tahminlemek için üç farklı ağ kurulmuştur. Girdi verileri, lif tipi, iplik numarası, hav uzunluğu olmak üzere üç tane iplik parametresi ile atkı sıklığı, kumaş kalınlığı ve kumaş gramajı olmak üzere üç tane kumaş parametresinden oluşmaktadır. Veri girişlerinde lif türleri için sayısal değerler atanmıştır. Polyester için 1, akrilik için 2 ve viskon için 3 sayısal değer atanarak kategorik veri oluşturulmuştur. Çıktı verisi olarak atkı-çözgü yönünde kopma mukavemeti ve aşınma direnci kullanılmıştır. Girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan oluşan yapay sinir ağı şematik olarak Şekil 7.10'da verilmiştir. Her bir çıktı için oluşturulan ağ yapısı, bahsi geçen girdi-çıkış parametreleri ile üç ağ çeşidi için MATLAB araç kutusunun sunduğu fonksiyonlarla çeşitli denemeler sonucu ayarlanmıştır.



Şekil 7.10. Verilerle oluşturulan yapay sinir ağı modeli

Ağ türü (network type) olarak “feed-forward back propagation”, “elman back propagation” ve “radial basis” denenmiştir. Eğitim fonksiyonu (training function) olarak “trainlm”, “trainbr”, “trainbfg” ve “traingda” denenmiştir. Adaptasyon öğrenim fonksiyonu (adaption learning function) olarak “learnsgdm”, performans fonksiyonu (performance function) olarak “mse” seçilmiştir. Transfer fonksiyonu (transfer function) seçimi için “tansig-tansig”, “tansig-logsig” ve “tansig-purelin” olmak üzere farklı fonksiyon kombinasyonları ile denemeler yapılmıştır. Gizli katmanda 10, 12, 20 ve 50 nöron ile denemeler yapılmıştır. Bu denemeler için çıktı olarak atki yönünde kopma mukavemet değerleri girilmiş ve ilk ağ (YSA 1) yapısı üzerinden gidilmiştir. İkinci ve üçüncü ağ yapıları (YSA 2 ve YSA 3) bu ağ yapısı örnek alınarak denemelerle kurulmuştur. Ağ yapısının belirlenmesinde kullanılan deneme kombinasyonları Çizelge 7.4’te verilmiştir. Bu seçim yapılırken oluşturulan ağların sadece genel regresyon değerlerine bakılmamış, ağın başarısını göstermede etkili OMYH değeri de göz önünde bulundurulmuştur. Aksi takdirde genel regresyon değeri yüksek birçok ağ bulunduğu için seçim yapmak zor olmaktadır.

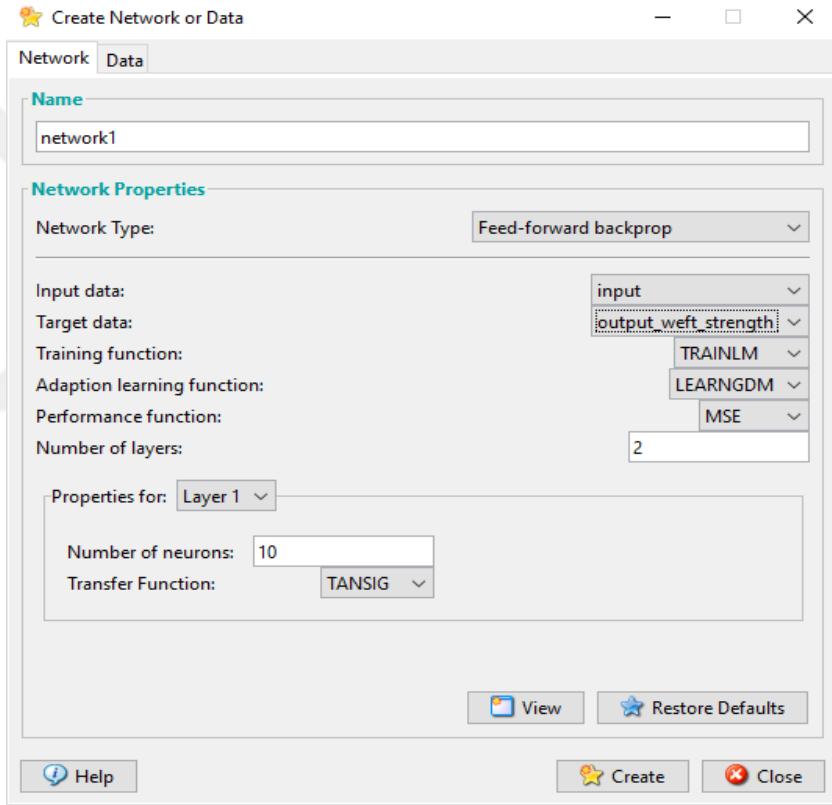
Çizelge 7.4. Ağ yapısını belirlemede kullanılan deneme kombinasyonları - I

Ağ Türü	Eğitim Fonksiyonu	Transfer Fonksiyonu	Nöron sayısı	Genel Regresyon	OMYH
feed-forward back propagation	trainlm	tansig-purelin	10	0.98	4.88
feed-forward back propagation	trainlm	tansig-purelin	12	0.96	14.91
feed-forward back propagation	trainlm	tansig-purelin	20	0.90	78.66
feed-forward back propagation	trainlm	tansig-purelin	50	0.96	35.24
elman back propagation	trainlm	tansig-purelin	10	0.96	19.92
radial basis (fewer neurons)	-	-	42	-	35.39
feed-forward back propagation	trainlm	tansig-tansig	10	0.96	7.67
feed-forward back propagation	trainlm	tansig-logsig	10	-0.02	151.31
feed-forward back propagation	trainbr	tansig-purelin	10	0.91	15.16
feed-forward back propagation	trainbfg	tansig-purelin	10	0.94	9.11
feed-forward back propagation	traingda	tansig-purelin	10	0.90	39.43


İlk ağ yapısı için altı girdi kullanılarak çıktı olarak atkı yönünde kopma mukavemeti değerleri seçilmiştir (YSA 1). Ağ türü olarak “feed-forward back propagation”, eğitim fonksiyonu olarak “trainlm” ve gizli katmanda 10 nöron kullanılarak en iyi sonuçlar alınmıştır (Şekil 7.11 ve Şekil 7.12). Ayrıca ilk katmanda “tansig” ikinci katmanda “purelin” seçilmiştir. Eğitim parametrelerinden (training parameters) min_grad değeri $1e^{-07}$ ve max_fail değeri 6 olarak seçilmiştir (Şekil 7.13).

İleri beslemeli (feed-forward) ağ, sinir ağlarını eğitmek için yaygın olarak geri yayılım (back propagation) (GY) ile birlikte kullanılır. İleri beslemeli GY ağının ana kullanımı, girdiler ve çıktılar arasındaki ilişkileri öğrenmek ve haritalamaktır. Ayrıca, minimum hatayı elde etmek için bir sistemin ağırlık değerlerini ve eşik değerlerini ayarlamak için kullanılır. GY, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı bu ismi almıştır. GY öğrenme kuralı ağ çıkışındaki mevcut hata düzeyine göre her bir katmandaki ağırlıkları yeniden hesaplamak için kullanılmaktadır (Shaik ve ark., 2020). Levenberg-Marquardt (trainlm) algoritması, parametrelerden oluşan bir uzay üzerinde minimum bir fonksiyonu (doğrusal veya doğrusal olmayan) bulmak için kullanılan popüler bir güven bölgesi algoritmasıdır. Temel olarak fonksiyonunun güvenilen bir bölgesi, ikinci

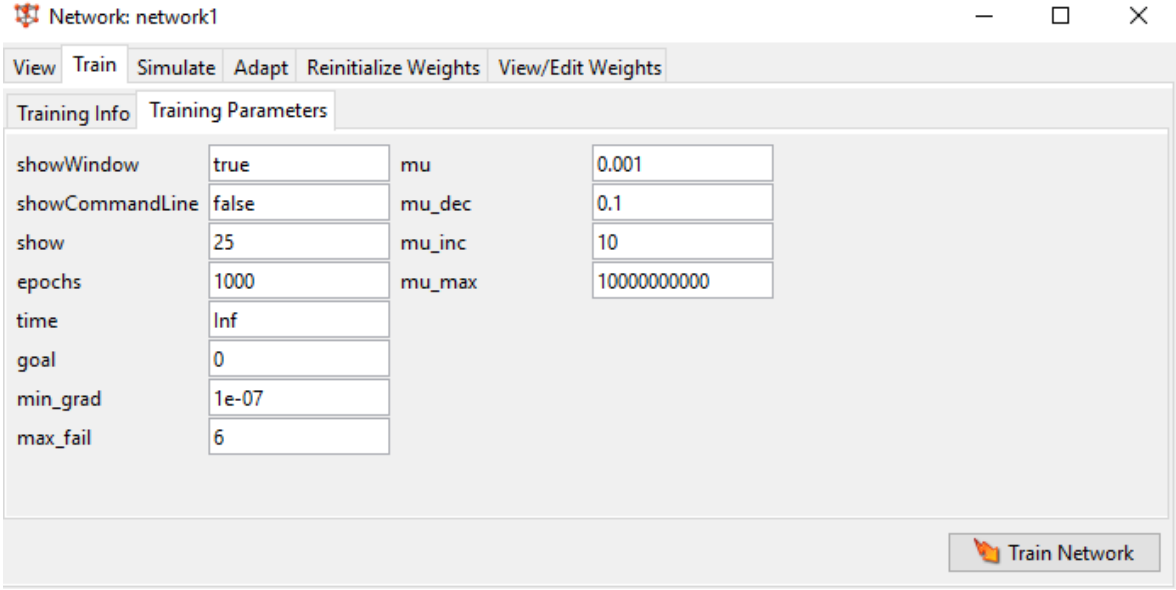
dereceden bir fonksiyon gibi dahili olarak modellenir. Yeterli uyum bulunduğunda güven bölgesi genişletilir (Farber, 2011). Yapay sinir ağlarında nöronlar çıktılarını üretmek için herhangi bir türevlenebilir transfer fonksiyonu kullanmaktadır. Tan-sigmoid (tansig) transfer fonksiyonunun dinamik değişim aralığı $[-1 \ 1]$ aralığıdır ve fonksiyon toplam nöron girişine bağımlı olarak bu aralıkta lineer olmayan bir değişim gösterir. Bu fonksiyon literatürde hiperbolik-tanjant fonksiyonu olarak da isimlendirilmektedir. Log-sigmoid (logsig) transfer fonksiyonunun dinamik değişim aralığı $[0 \ 1]$ aralığıdır ve fonksiyon bu aralıkta lineer olmayan bir değişim sergiler. Lineer (purelin) transfer fonksiyonunda nöron girişlerinin değişimine göre nöron çıkışı lineer olarak değişmektedir. Dinamik değişim aralığı $[-1 \ 1]$ aralığıdır.



Şekil 7.11. YSA 1'i oluşturmak için gerekli parametreler




Şekil 7.12. YSA 1 mimarisi

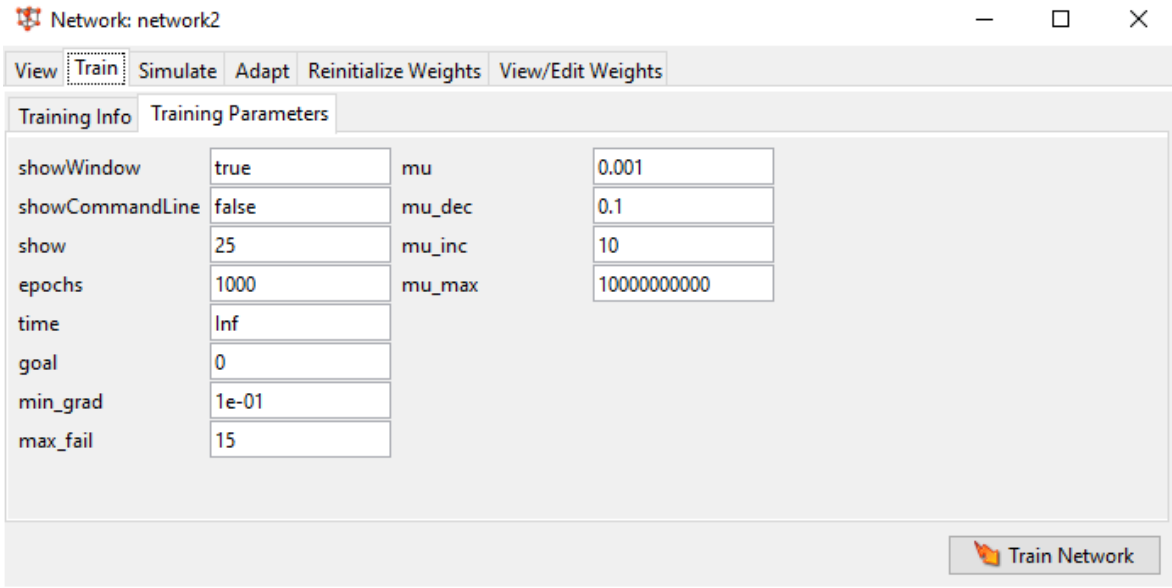


Şekil 7.13. YSA 1 eğitim parametreleri

İkinci ağ yapısı için, yine altı girdi kullanılarak çıktı olarak çözgü yönünde kopma mukavemeti değerleri seçilmiştir (YSA 2). Diğer parametreler birinci ağ yapısıyla aynı kalmak şartıyla, bu ağda farklı olarak gizli katmanda 35 nöron kullanılmıştır (Şekil 7.14). Ayrıca eğitim parametrelerinden min_grad değeri $1e^{-1}$ ve max_fail değeri 15 olarak seçilmiştir (Şekil 7.15). “min_grad” parametresi, sinir ağı eğitiminin sonlandığı gradyan inişinin minimum büyüklüğünü belirtmektedir. Gradyan inişinin büyüklüğü “min_grad”dan daha az olduğunda, sinir ağının optimize edildiği belirtilmiştir. “max_fail” değeri ise doğrulama duraklamaları olarak kullanılmaktadır. Bu değer sınırsız (infinite) olursa, hata ve ağırlık değerlerinin optimum bir kombinasyonu bulunana kadar eğitim devam edebilir. Ancak, max_fail 6’ya veya başka bir kesinlikte pozitif değere ayarlanarak doğrulama etkinleştirilirse, daha kısa eğitim süreleriyle birlikte ağırlık minimizasyonu elde edilebilmektedir.




Şekil 7.14. YSA 2 mimarisi

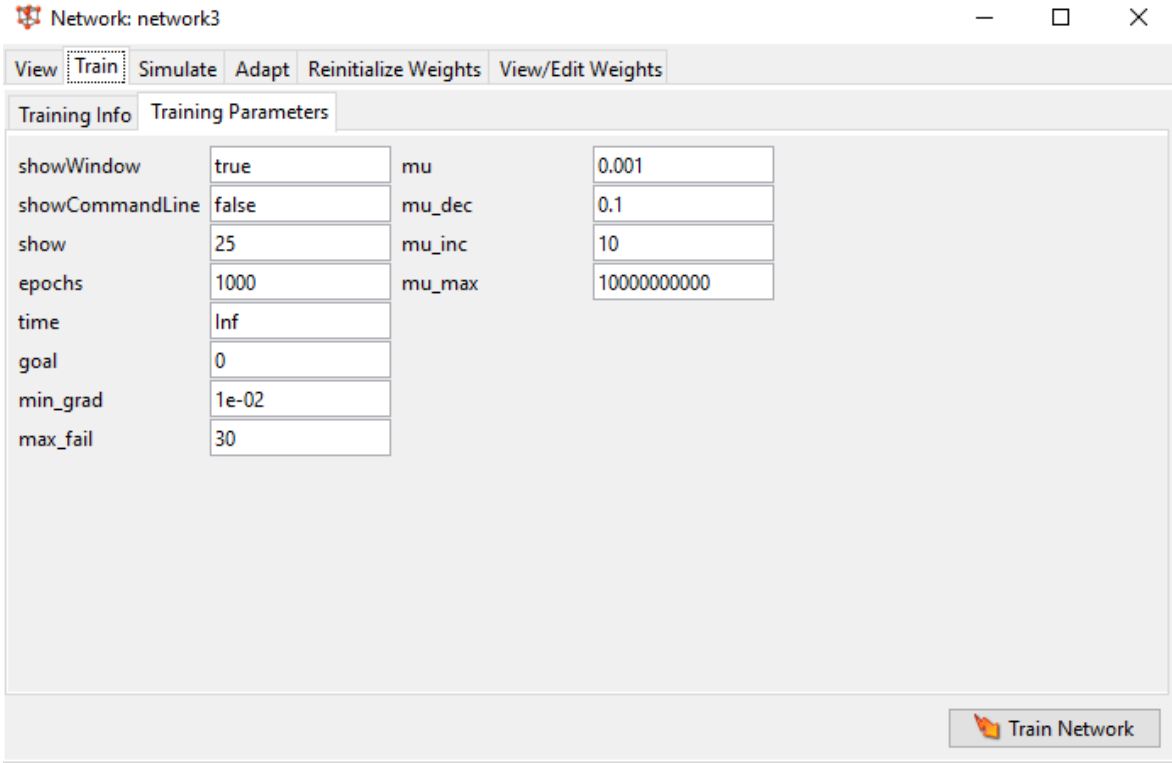


Şekil 7.15. YSA 2 eğitim parametreleri

Son ağ yapısı için, aynı altı girdi kullanılarak çıktı olarak aşınma direnci değerleri seçilmiştir (YSA 3). Diğer parametreler birinci ağ yapısıyla aynı kalmak şartıyla, bu ağda farklı olarak gizli katmanda 20 nöron kullanılmıştır (Şekil 7.16). Ayrıca eğitim parametrelerinden min_grad değeri $1e^{-02}$ ve max_fail değeri 30 olarak seçilmiştir (Şekil 7.17).



Şekil 7.16. YSA 3 mimarisi



Şekil 7.17. YSA 3 eğitim parametreleri

7.2.6.2. Kumaş yüzey özellikleri kullanarak tahminleme için YSA modelleri

MATLAB 2020a versiyonunda sinir ağı araç kutusu kullanılmıştır. Modifiye resnet101 ağı ile çıkarılan özelliklerin ortalaması alınmış ve bunlar girdi verisi olarak kullanılmıştır (toplamda 48 girdi verisi elde edilmiştir). Çıktı verisi olarak yine atkı-çözgü yönünde kopma mukavemeti ve aşınma direnci kullanılmıştır. Önceki üç modelde olduğu gibi her bir çıktı için ayrı bir model oluşturulmuştur. Yeni üç ağ çeşidi de MATLAB araç kutusunun sunduğu fonksiyonlarla çeşitli denemeler sonucu ayarlanmıştır.

Ağ türü (network type) olarak “feed-forward back propagation” ve “elman back propagation” ile denemeler yapılmıştır. Eğitim fonksiyonu (training function) olarak “trainlm”, “trainbr” ve “trainscg” denenmiştir. Transfer fonksiyonu (transfer function) olarak ilk ve ikinci katmanda “tansig-tansig”, “tansig-purelin” ve “logsig-purelin” ile kombinasyonlar yapılmıştır. Gizli katmanda 8, 16, 24, 36 ve 48 nöron ile denemeler yapılmıştır. Bu denemeler için çıktı olarak çözgü yönünde kopma mukavemet değerleri girilmiş ve ikinci ağ (YSA/R 2) yapısı üzerinden gidilmiştir. Birinci ve üçüncü ağ yapıları (YSA/R 1 ve YSA/R 3) bu ağ yapısı örnek alınarak denemelerle kurulmuştur. Ağ yapısının belirlenmesinde kullanılan deneme kombinasyonları Çizelge 7.5’te verilmiştir.


Çizelge 7.5. Ağ yapısını belirlemede kullanılan deneme kombinasyonları - II

Ağ Türü	Eğitim Fonksiyonu	Transfer Fonksiyonu	Nöron sayısı	Genel Regresyon	OMYH
feed-forward back propagation	trainlm	tansig-purelin	8	0.96	12.23
feed-forward back propagation	trainlm	tansig-purelin	16	0.96	20
feed-forward back propagation	trainlm	tansig-purelin	24	0.85	20.42
feed-forward back propagation	trainlm	tansig-purelin	36	0.89	17.82
feed-forward back propagation	trainlm	tansig-purelin	48	0.89	16.01
feed-forward back propagation	trainlm	tansig-tansig	8	0.85	21
feed-forward back propagation	trainlm	tansig-tansig	16	0.97	14.92
feed-forward back propagation	trainlm	tansig-tansig	24	0.94	19.12
feed-forward back propagation	trainlm	logsig-purelin	8	0.94	19.31
feed-forward back propagation	trainbr	tansig-purelin	8	0.96	13.74
feed-forward back propagation	trainscg	tansig-purelin	8	0.93	14.79
elman back propagation	trainlm	tansig-purelin	8	0.97	16.57
elman back propagation	trainlm	logsig-purelin	8	0.96	19.01

İlk ağ için 48 girdi kullanılarak çıktı olarak atkı yönünde kopma mukavemeti değerleri seçilmiştir (YSA/R 1). Ağ türü olarak “elman back propagation” seçilmiştir. Eğitim fonksiyonu olarak “trainlm” ve transfer fonksiyonu olarak “tansig-tansig” yapısı seçilmiştir. Gizli katmanda 10 nöron kullanılmıştır (Şekil 7.18). Eğitim parametrelerinden min_grad değeri $1e^{-07}$ ve max_fail değeri 6 olarak seçilmiştir.


Elman ağı üç katmanlı bir sinir ağıdır. İkinci katman, iki farklı nöron gurubundan oluşmuştur. Bunlar, harici giriş nöronları gurubu ve dahili giriş nöronları olarak da adlandırılan geciktirme üniteleri gurubudur. Giriş katmanı nöronları sadece tampon görevi yapmaktadır ve gelen sinyali değiştirmeden geçirmektedir. Geciktirme üniteleri için giriş, gizli katman nöronlarının çıkışlarıdır. Bu ağlarda, gizli katmandaki önceki durumlar hafıza olarak saklanarak girişe verilmekte ve bu durumda ağın çıkışı o anki ve önceki girişe bağlı olarak belirlenmektedir. Bu yapı dinamik hafıza olarak görev yapmaktadır (Kalınlı, 2002). Elman ağı, ikinci katmanın tekrarlayan bir bağlantıya sahip olması bakımından geleneksel

ağlardan farklıdır. Bu bağlantıdaki gecikme, geçerli zaman adımında kullanılabilen önceki zaman adımından gelen değerleri depolamaktadır. Dolayısıyla, aynı ağırlıklara ve eşik değerlerine sahip iki Elman ağına belirli bir zaman adımında özdeş girdiler verilse bile, farklı geri bildirim durumları nedeniyle çıktıları farklı olabilmektedir.




Şekil 7.18. YSA/R 1 mimarisi

İkinci ağ yapısı için, 48 girdi kullanılarak çıktı olarak çözümlenme mukavemeti değerleri seçilmiştir (YSA/R 2). Ağ türü olarak “feed-forward back propagation” seçilmiştir. Eğitim fonksiyonu olarak “trainlm” ve transfer fonksiyonu olarak “tansig-purelin” yapısı seçilmiştir. Gizli katmanda 8 nöron kullanılmıştır (Şekil 7.19). Eğitim parametrelerinden (training parameters) min_grad değeri $1e^{-07}$ ve max_fail değeri 6 olarak seçilmiştir.



Şekil 7.19. YSA/R 2 mimarisi

Son ağ yapısı için, 48 girdi kullanılarak çıktı olarak aşınma direnci değerleri seçilmiştir (YSA/R 3). YSA/R 2 ağından farklı olarak, transfer fonksiyonu “logsig-purelin” seçilmiş ve gizli katmanda 16 nöron kullanılmıştır (Şekil 7.20). Eğitim parametrelerinden min_grad değeri $1e^{-07}$ ve max_fail değeri 15 olarak seçilmiştir.



Şekil 7.20. YSA/R 3 mimarisi



8. BULGULAR VE TARTIŞMA

8.1. Performans Test Sonuçları

Belirtilen standartlara göre yapılan atkı ve çözgü yönünde kopma mukavemeti ile aşınma direnci test sonuçlarının ortalamaları Çizelge 8.1’de özetlenmiştir.

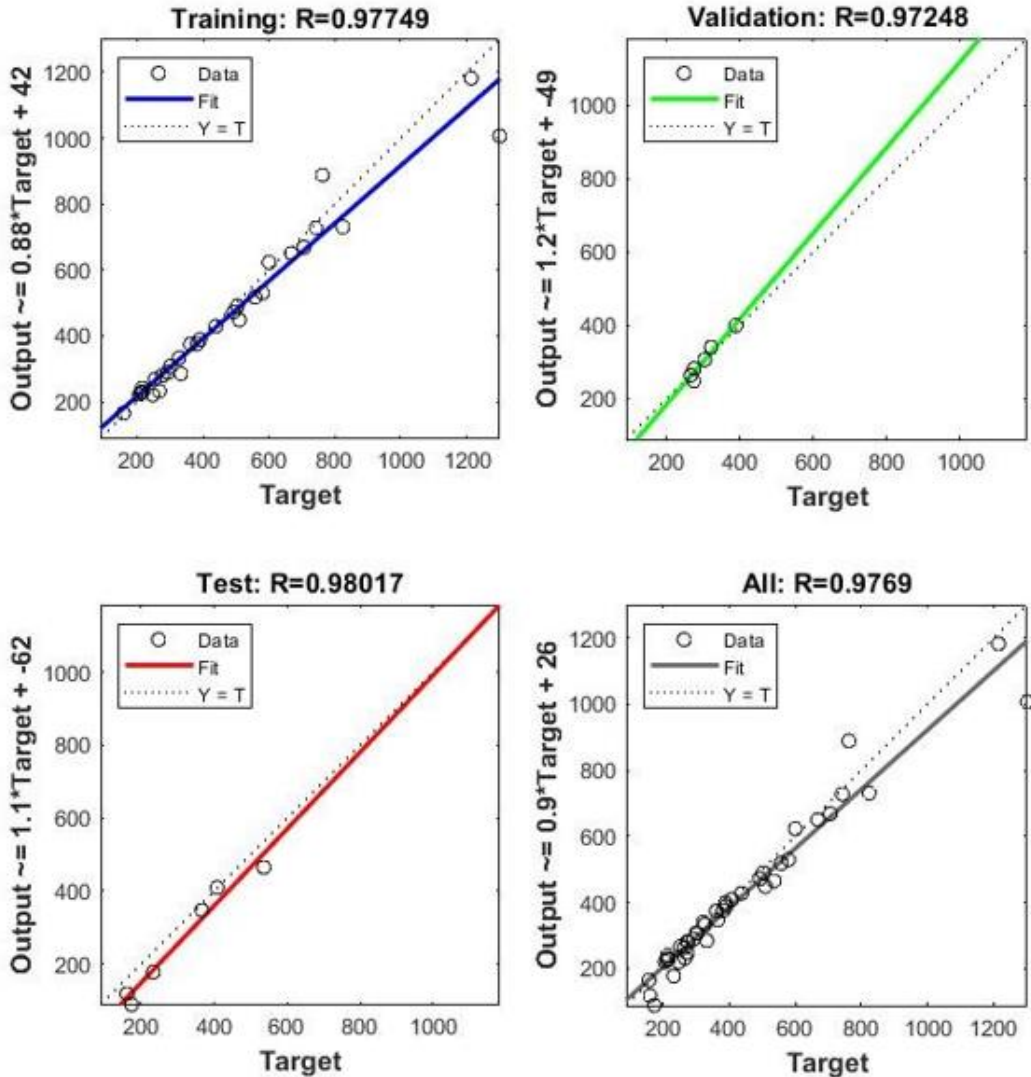
Çizelge 8.1. Performans test sonuçları

Sample No	Kopma mukavemeti (atkı yönünde) (N)	Kopma mukavemeti (çözgü yönünde) (N)	Aşınma direnci (kopmadaki tur sayısı)
1	361.7	1284.4	68000
2	303.0	1240.1	56000
3	303.2	1120.0	46000
4	301.0	1040.2	36000
5	388.4	1396.7	39000
6	357.6	1243.3	36000
7	327.0	1383.2	40000
8	438.2	1192.8	60000
9	705.8	1754.9	44000
10	668.2	1503.8	85000
11	600.3	1675.9	60000
12	742.0	1108.4	40000
13	1214.2	1516.0	30000
14	1300.7	1547.0	22000
15	762.2	1433.1	36000
16	823.7	1287.2	35000
17	158.0	1260.8	60000
18	161.2	1276.9	62000
19	165.5	1342.5	36000
20	174.1	1242.3	36000
21	216.9	1742.6	24000
22	206.6	1790.0	44000
23	247.3	1334.2	35000
24	215.1	1525.4	39000
25	503.7	1803.6	36000
26	492.3	1716.8	36000
27	411.6	1874.4	26000
28	381.9	1846.2	37000
29	580.3	1944.7	14000
30	557.4	1656.1	24000
31	536.3	1897.5	15000
32	509.7	1907.9	18000
33	232.8	1320.9	40000
34	273.7	1150.1	46000
35	390.5	1451.9	64000
36	321.2	1066.8	40000
37	264.9	1574.4	20000
38	253.9	1634.0	40000
39	292.7	1568.8	40000
40	328.9	1311.2	50000
41	276.6	1567.2	25000
42	273.8	1400.2	36000
43	267.0	1379.1	11000
44	212.7	1020.8	19000
45	407.9	1425.2	13000
46	365.7	1523.9	11000
47	326.0	1294.4	9000
48	332.2	1258.6	10000

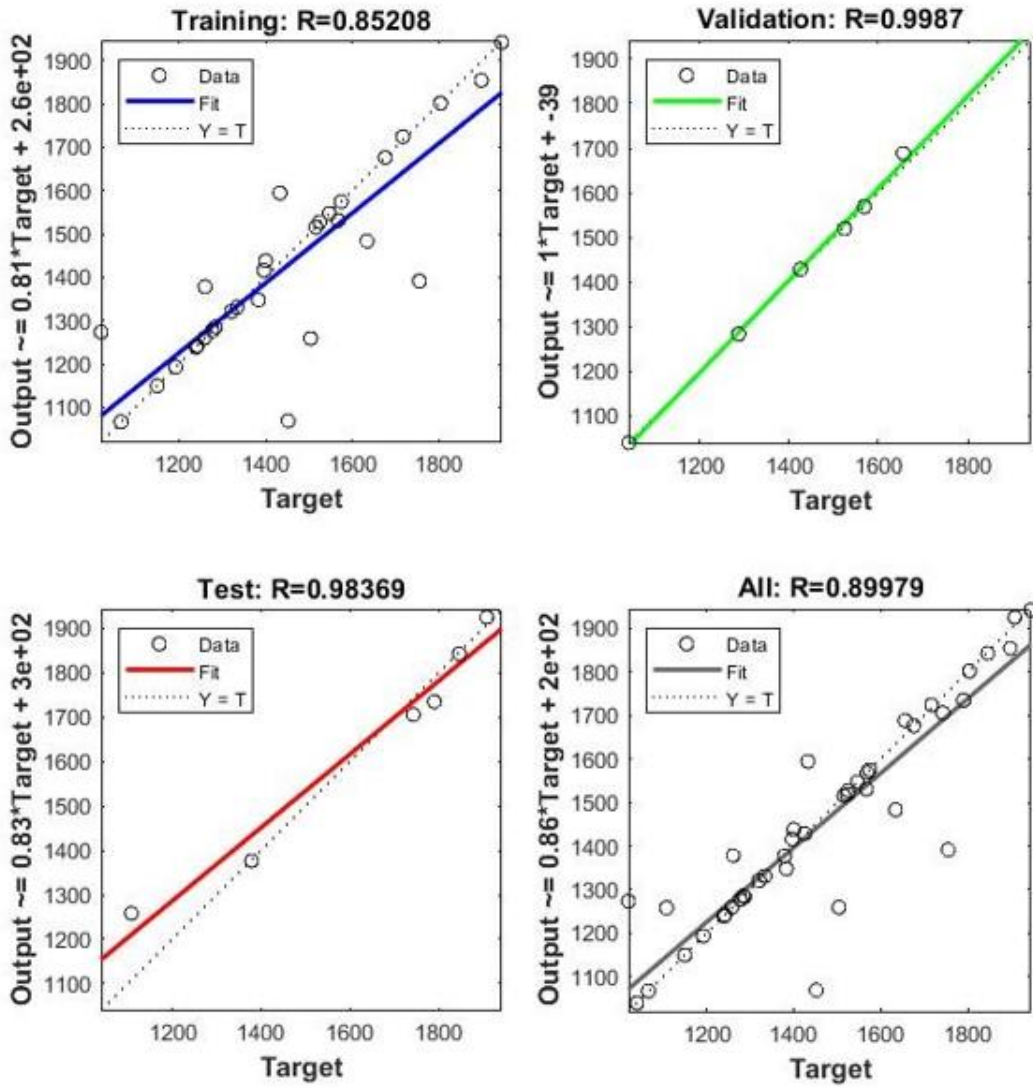
8.2. YSA 1, YSA 2 ve YSA 3 Modelleri Öğrenme Performansı

MATLAB'ta yapay sinir ağları ile kurulan modellerde 42 adet numune eğitim için, 6 adet numune (3, 6, 19, 27, 40, 47 numaralı numuneler) ise kurulan ağın ne derece başarılı olduğunu tespit etmede simülasyon için ayrılmıştır. Simülasyon için ayrılan numuneler her lif grubundan farklı numaralarda iplikler de içerecek şekilde seçilmiş ve bu numuneler ağlarda eğitilmemiştir. Eğitim için ayrılan 42 adet numune sinir ağı araç kutusunda %70'i eğitim, %15'i doğrulama ve %15'i test için olmak üzere üç gruba ayrılmıştır.

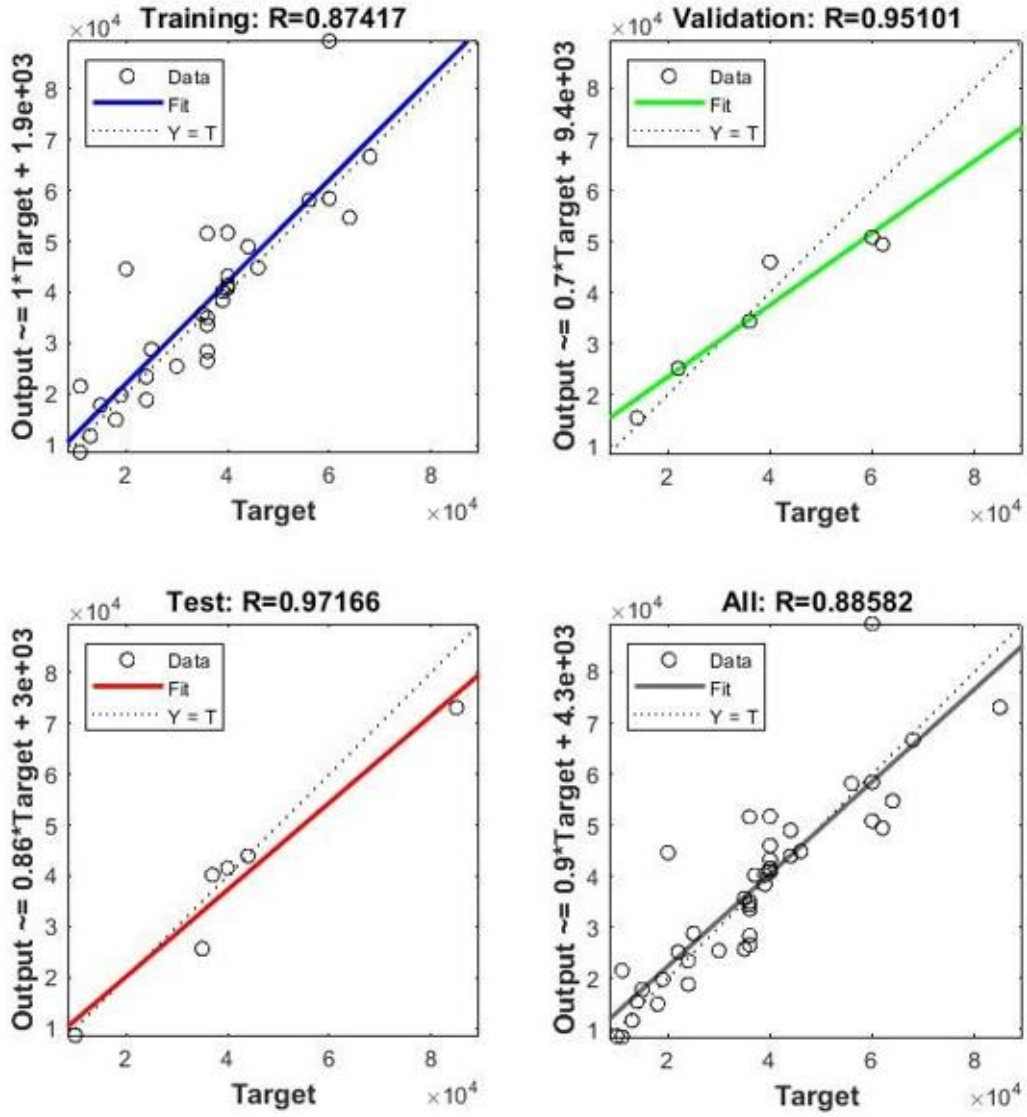
Atkı-çözgü yönünde kopma mukavemetleri ile aşınma direnci olmak üzere üç çıktı parametresi için eğitim, doğrulama, test ve genel regresyon sonuçları Şekil 8.1, Şekil 8.2 ve Şekil 8.3'te gösterilmiştir. Ağ modellerinin genel regresyon sonuçlarına bakıldığında YSA 1, YSA 2 ve YSA 3 için sırasıyla $R = 0.98$, $R = 0.90$ ve $R = 0.89$ gibi yüksek değerlere sahip olduğu görülecektir.



Şekil 8.1. YSA 1 regresyon sonuçları



Şekil 8.2. YSA 2 regresyon sonuçları

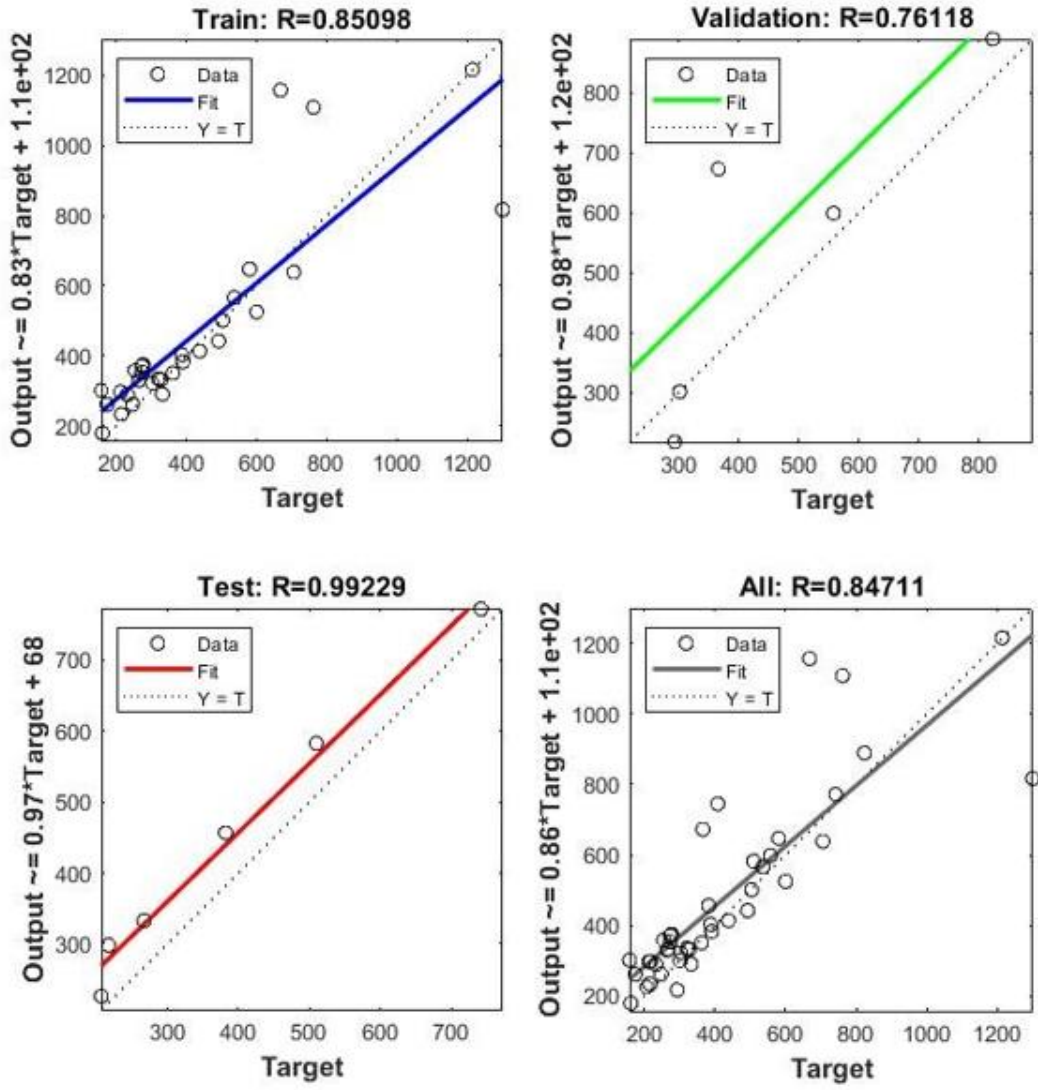


Şekil 8.3. YSA 3 regresyon sonuçları

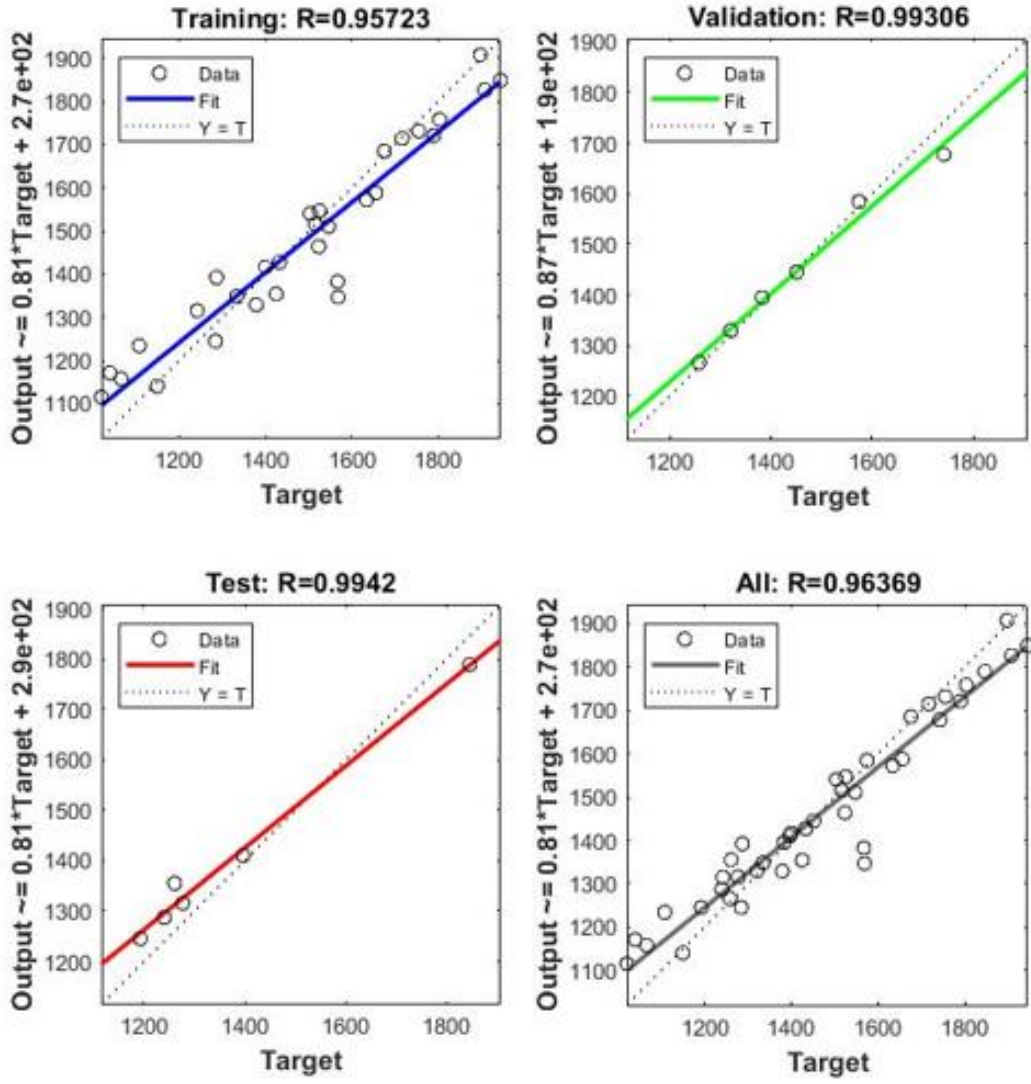
8.3. YSA/R 1, YSA/R 2 ve YSA/R 3 Modelleri Öğrenme Performansı

MATLAB'ta yapay sinir ağları ile kurulan bu modellerde de 42 adet numune eğitim için, 6 adet numune (önceki modellerde ayrılan numuneler) ise kurulan ağın ne derece başarılı olduğunu tespit etmede simülasyon için ayrılmıştır. Eğitim için ayrılan 42 adet numune sinir ağı araç kutusunda %70'i eğitim, %15'i doğrulama ve %15'i test için olmak üzere üç gruba ayrılmıştır.

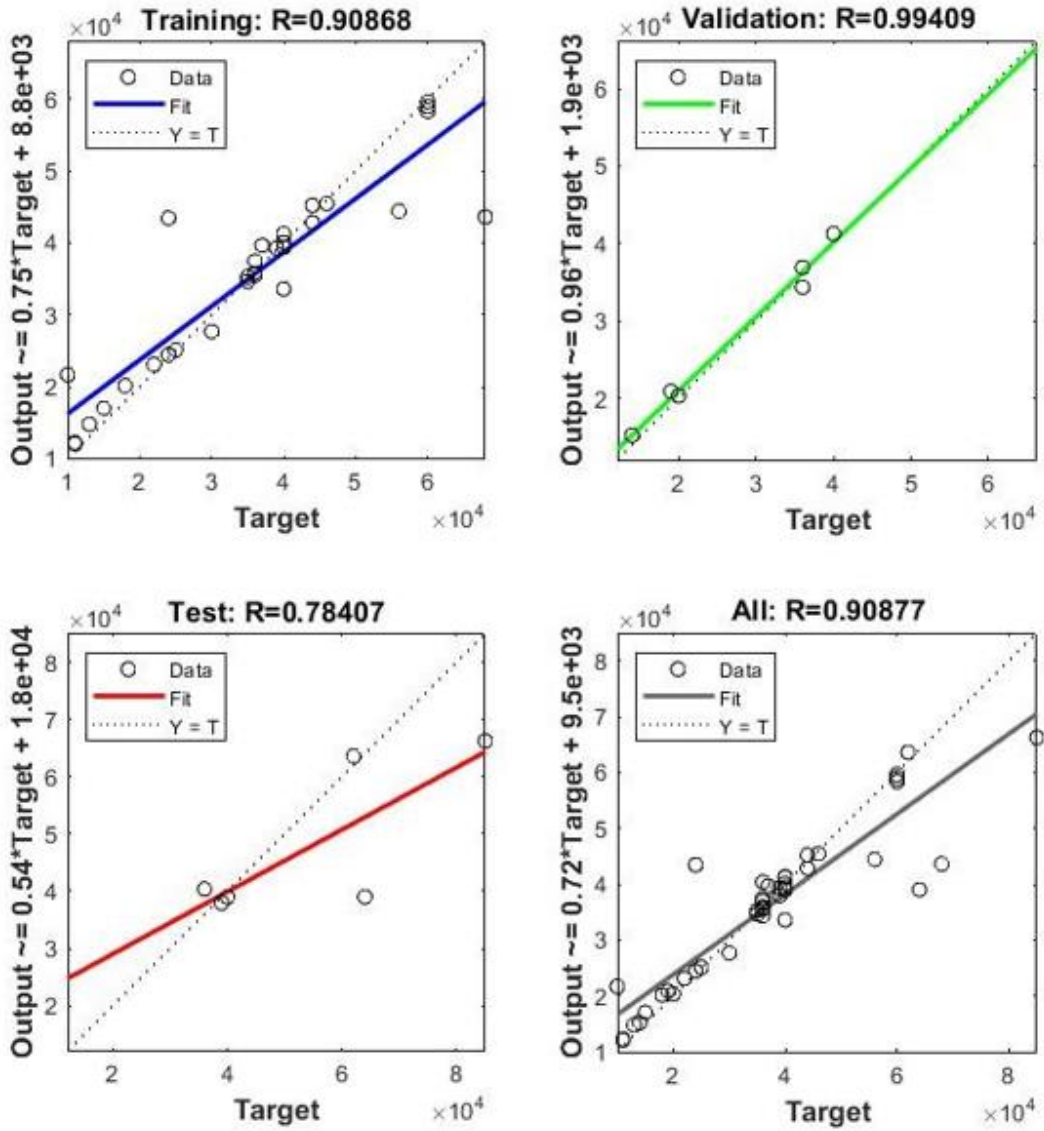
Atkı-çözgü yönünde kopma mukavemetleri ile aşınma direnci olmak üzere üç çıktı parametresi için eğitim, doğrulama, test ve genel regresyon sonuçları Şekil 8.4, Şekil 8.5 ve Şekil 8.6'da gösterilmiştir. Ağ modellerinin genel regresyon sonuçlarına bakıldığında YSA/R 1, YSA/R 2 ve YSA/R 3 için sırasıyla $R = 0.85$, $R = 0.96$ ve $R = 0.91$ gibi yüksek değerlere sahip olduğu görülecektir.



Şekil 8.4. YSA/R 1 regresyon sonuçları



Şekil 8.5. YSA/R 2 regresyon sonuçları



Şekil 8.6. YSA/R 3 regresyon sonuçları

8.4. Oluşturulan Modellerin Tahminleme Sonuçları

Modellerin oluşturulmasından, tahminleme sonuçlarının değerlendirilmesine kadar olan süreç Şekil 8.7’de verilen akışa göre gerçekleştirilmiştir. Hem iplik ve kumaş verilerinin hem de kumaş yüzey özelliklerinin girdi olarak kullanılmasında aynı yol izlenmiştir.




Şekil 8.7. Modelleme akış diyagramı

8.4.1. Atkı yönünde kopma mukavemeti tahminleme sonuçları (YSA 1 ve YSA/R 1)

Atkı yönünde kopma mukavemetinin deneysel sonuçları ile YSA 1 ve YSA/R 1 simülasyon tahmin sonuçları Çizelge 8.2’de karşılaştırılmıştır. Çizelge 8.2, YSA 1’in en yüksek hata yüzdesinin %9.26, en düşük hata yüzdesinin ise %1.71 olduğunu göstermektedir. YSA 1 için, yüzde hata değerlerinin ortalaması ile hesaplanan, ortalama mutlak yüzdesel hata (OMYH) değeri %4.88 olarak bulunmuştur. YSA/R 1’in en yüksek hata yüzdesi %29.32, en düşük hata yüzdesi ise %7.50’dir. YSA/R 1 için OMYH değeri %17.42 olarak bulunmuştur. Şekil 8.8 deneysel ve tahmin sonuçları arasındaki ilişkiyi göstermektedir. Deney ve tahmin sonuçları arasındaki doğrusal regresyon sonucu, YSA 1 için $R = 0.98$, $R^2 = 0.95$ ve YSA/R 1 için $R = 0.78$, $R^2 = 0.60$ olarak bulunmuştur. YSA 1 modelinin tahmin başarısının, YSA/R 1 modeline üstünlüğü R , R^2 ve OMYH değerlerinden açıkça görülmektedir. YSA 1’deki güçlü ilişki, girdi parametrelerinin atkı yönünde kopma mukavemetini ne ölçüde etkilediğinin bir göstergesidir.

Çizelge 8.2. Atkı yönünde kopma mukavemeti tahmin sonuçları

Numune no	Deneysel sonuçlar (N)	YSA 1		YSA/R 1	
		Tahmin sonuçları (N)	Hata (%)	Tahmin sonuçları (N)	Hata (%)
3	303.20	290.69	4.13	325.94	7.50
6	357.60	345.26	3.45	307.14	14.11
19	165.50	174.87	5.66	201.08	21.50
27	411.60	418.63	1.71	461.00	12.00
40	328.90	312.32	5.04	262.84	20.09
47	326.00	356.18	9.26	421.58	29.32




Şekil 8.8. Atkı yönünde kopma mukavemeti için deneysel ve tahmin değerlerinin doğrusal regresyonu

8.4.2. Çözgü yönünde kopma mukavemeti tahminleme sonuçları (YSA 2 ve YSA/R 2)

Çözgü yönünde kopma mukavemetinin deneysel sonuçları ile YSA 2 ve YSA/R 2 simülasyon tahmin sonuçları Çizelge 8.3'te karşılaştırılmıştır. Çizelge 8.3, YSA 2'in en yüksek hata yüzdesinin %14.90, en düşük hata yüzdesinin ise %3.71 olduğunu göstermektedir. YSA 2 için, OMYH değeri %12.13 olarak bulunmuştur. YSA/R 2'in en yüksek hata yüzdesi %32.19, en düşük hata yüzdesi ise %1.33'dür. YSA/R 2 için OMYH değeri %12.23 olarak bulunmuştur. Şekil 8.9 deneysel ve tahmin sonuçları arasındaki ilişkiyi göstermektedir. Deney ve tahmin sonuçları arasındaki doğrusal regresyon sonucu, YSA 2 için $R = 0.86$, $R^2 = 0.74$ ve YSA/R 2 için $R = 0.73$, $R^2 = 0.54$ olarak bulunmuştur. YSA 2 modeli ve YSA/R 2 modelinin tahmin başarılarına bakıldığında R ve R^2 değerlerinden YSA 2 modeli daha başarılı gibi görünmektedir. Ancak her iki modelin OMYH değerlerinin çok yakın olması YSA/R 2'nin de başarılı olduğunu göstermektedir. YSA 1 ve YSA 2 modelinin doğrusal regresyon sonuçları karşılaştırıldığında YSA 2'nin daha düşük olduğu görülmektedir. Bu durum şönil ipliklerinin atkıda kullanılması ve çözgü ipliklerinin sabit olması nedeniyle, girdi parametrelerinin çözgü yönü mukavemeti üzerinde atkı yönü mukavemeti kadar etkili olmaması ile açıklanabilmektedir.

Çizelge 8.3. Çözgü yönünde kopma mukavemeti tahmin sonuçları

Numune no	Deneysel sonuçlar (N)	YSA 2		YSA/R 2	
		Tahmin sonuçları (N)	Hata (%)	Tahmin sonuçları (N)	Hata (%)
3	1120.00	976.45	12.82	1024.60	8.52
6	1243.30	1428.60	14.90	1563.60	25.76
19	1342.50	1243.84	7.35	1389.60	3.51
27	1874.40	1739.03	7.22	1835.40	2.08
40	1311.20	1359.87	3.71	1293.80	1.33
47	1294.40	1376.10	6.31	877.79	32.19



Şekil 8.9. Çözgü yönünde kopma mukavemeti için deneysel ve tahmin değerlerinin doğrusal regresyonu


8.4.3. Aşınma direnci tahminleme sonuçları (YSA 3 ve YSA/R 3)

Aşınma direnci deneysel sonuçları ile YSA 3 ve YSA/R 3 simülasyon tahmin sonuçları Çizelge 8.4'te karşılaştırılmıştır. Çizelge 8.4, YSA 3'ün en yüksek hata yüzdesinin %37.69, en düşük hata yüzdesinin ise %0.19 olduğunu göstermektedir. YSA 3 için, OMYH değeri %13.85 olarak bulunmuştur. YSA/R 3'ün en yüksek hata yüzdesi %73.26 en düşük hata yüzdesi ise %12.15'dir. YSA/R 3 için OMYH değeri %34.85 olarak bulunmuştur. Şekil 8.10 deneysel ve tahmin sonuçları arasındaki ilişkiyi göstermektedir. Deney ve tahmin sonuçları arasındaki doğrusal regresyon sonucu, YSA 3 için $R = 0.93$, $R^2 = 0.87$ ve YSA/R 3 için $R = 0.68$, $R^2 = 0.46$ olarak bulunmuştur. YSA 3 modelinin tahmin başarısının, YSA/R 3 modeline üstünlüğü R , R^2 ve OMYH değerlerinden görülmektedir. YSA 3'ten elde edilen sonuçlardan girdi parametreleri ile aşınma direnci arasındaki

ilişkinin yüksek olduğu görülmektedir. Ancak YSA/R 3'ün başarısı, YSA/R 1 ve YSA/R 2'ye göre oldukça sınırlı kalmıştır.

Çizelge 8.4. Aşınma direnci tahmin sonuçları

Numune no	Deneysel sonuçlar (tur sayısı)	YSA 3		YSA/R 3	
		Tahmin sonuçları (tur sayısı)	Hata (%)	Tahmin sonuçları (tur sayısı)	Hata (%)
3	46000	46087.50	0.19	51590.90	12.15
6	36000	37575.87	4.38	47478.20	31.88
19	36000	36672.13	1.87	23041.93	35.99
27	26000	35799.16	37.69	45048.62	73.26
40	50000	42353.41	15.29	40814.96	18.37
47	9000	11129.32	23.66	12370.55	37.45



Şekil 8.10. Aşınma direnci için deneysel ve tahmin değerlerinin doğrusal regresyonu

9. SONUÇLAR

Tez çalışması kapsamında belirli parametrelerle şönil iplikler üretilmiştir. Bu parametreler içerisinde iplik numarası, hav uzunluğu ve lif tipi yer almıştır. Lif tipini belirleyen hammaddeler olarak poliester, akrilik ve viskon lifleri kullanılmıştır. Her bir hammadde için şönil iplikler Nm 1, Nm 2, Nm 4 ve Nm 6 olmak üzere dört farklı numarada üretilmiştir. Her iplik numarası için dört farklı hav uzunluğu kullanılmıştır. Parametrelerin farklı kombinasyonlarıyla toplamda 48 adet şönil iplik üretilmiştir. Elde edilen şönil ipliklerin atkıda kullanılması ile 48 farklı dokuma kumaş elde edilmiştir (çözü olarak bütün kumaşlarda aynı poliester iplik kullanılmıştır). Tez çalışması kapsamında şönil iplik özellikleri (hav uzunluğu, iplik numarası, lif tipi) ve şönil kumaş özellikleri (atkı sıklığı, kumaş kalınlığı, kumaş gramajı) ile ayrıca şönil kumaş görüntü özelliklerinden; kopma mukavemeti ve aşınma direnci gibi performans özelliklerinin tahmin edilmesi amacı ile yapay sinir ağı modellerinin geliştirilmesi amaçlanmıştır. Bu amaçla iki farklı yöntem kullanılmıştır.

Çalışmadan elde edilen sonuçlar ve değerlendirme aşağıdaki gibi özetlenmiştir:

- İlk yöntemde girdi parametreleri, iplik numarası, hav uzunluğu ve lif tipi olmak üzere üç iplik özelliği ile atkı sıklığı, kumaş kalınlığı ve kumaş gramajı olmak üzere üç kumaş özelliğini kapsayan altı girdi parametresinden oluşmuştur.
- İlk yöntemdeki girdi parametreleri ile belirlenen performans özelliklerinin tahminlenmesi için yapay sinir ağı modelleri kurulmuş ve modellerin başarısı incelenmiştir. Atkı yönünde kopma mukavemeti için YSA 1, çözü yönünde kopma mukavemeti için YSA 2 ve aşınma direnci için YSA 3 modelleri oluşturulmuştur.
- MATLAB ortamında farklı parametreler ile ağı eğitim denemeleri yapılmıştır. En uygun parametreler belirlenerek eğitilen ağların toplam doğruluk oranları R değerine bağlı olarak değerlendirilmiştir. Geliştirilen YSA 1, YSA 2 ve YSA 3 ağlarının toplam doğruluk regresyon değerleri sırasıyla $R = 0.98$, $R = 0.90$ ve $R = 0.89$ şeklindedir.
- İkinci yöntemde ise şönil kumaş görüntülerinden çıkarılan yüzey özellikleri girdi parametresi olarak kullanılmıştır. Yüzey özelliği çıkarmak için derin öğrenme metodu kullanılarak önceden eğitilmiş çeşitli sinir ağları üzerinde gerekli değişiklikler yapılarak denemeler yapılmıştır. Çalışma kapsamında kullanılan ağlar (googlenet, resnet101, vgg16, vgg19 ve alexnet) arasında eğitim başarısı diğerlerinden çok yüksek olan resnet101 ağı

seçilmiştir. Toplamda 48 girdi parametresi elde edilmiş olup her bir parametre için ortalama değerler hesaplanmıştır.

- İkinci yöntemdeki girdi parametreleri ile belirlenen performans özelliklerinin tahminlenmesi için de yapay sinir ağı modelleri kurulmuş ve modellerin başarısı incelenmiştir. Atkı yönünde kopma mukavemeti için YSA/R 1, çözgü yönünde kopma mukavemeti için YSA/R 2 ve aşınma direnci için YSA/R 3 modelleri kullanılmıştır.

- İkinci yöntemde modellerin MATLAB'tan alınan öğrenme başarı düzeylerine bakıldığında YSA/R 1, YSA/R 2 ve YSA/R 3 için sırasıyla $R = 0.85$, $R = 0.96$ ve $R = 0.91$ gibi yüksek değerlere sahip olduğu görülmüştür.

- Her iki yöntem için MATLAB'tan alınan çıktılarla birlikte modeli daha sağlıklı değerlendirebilmek adına, modeller oluşturulurken kullanılmayıp ayrılan verilerin (48 adet numunenin 6'sı model eğitimlerinde kullanılmamıştır) performans özellikleri, modeller üzerinden tahminlemeye tabi tutulmuştur.

- Atkı yönünde kopma mukavemeti tahminleme sonuçları her iki yöntem için de değerlendirilmiştir. YSA 1 için $R = 0.98$, $R^2 = 0.95$, OMYH = %4.88 ve YSA/R 1 için $R = 0.78$, $R^2 = 0.60$, OMYH = %17.42 olarak bulunmuştur. İlk yöntemdeki girdilerle elde edilen YSA 1'in, ikinci yöntemdeki yüzey özellikleri kullanılarak elde edilen YSA/R 1'e göre çok daha başarılı olduğu R , R^2 ve OMYH değerlerinden açıkça görülmüştür. YSA 1'deki güçlü ilişki, girdi parametrelerinin atkı yönünde kopma mukavemetini ne ölçüde etkilediğini göstermiştir. Ancak hiçbir iplik ve kumaş özelliği bilinmeden sadece kumaş görüntülerinden yola çıkarak tahminleme yapan YSA/R 1 de başarısız olarak değerlendirilmemiştir.

- Çözgü yönünde kopma mukavemeti tahminleme sonuçları her iki yöntem için de değerlendirilmiştir. YSA 2 için $R = 0.86$, $R^2 = 0.74$, OMYH = %12.13 ve YSA/R 2 için $R = 0.73$, $R^2 = 0.54$, OMYH = %12.23 olarak bulunmuştur. YSA 2 modeli ve YSA/R 2 modelinin tahmin başarılarına bakıldığında R ve R^2 değerlerinden YSA 2 modeli daha başarılı gibi görünmektedir. Ancak her iki modelin OMYH değerlerinin çok yakın olması YSA/R 2'nin de başarılı olduğunu göstermiştir.

- Aşınma direnci tahminleme sonuçları her iki yöntem için de değerlendirilmiştir. YSA 3 için $R = 0.93$, $R^2 = 0.87$, OMYH = %13.85 ve YSA/R 3 için $R = 0.68$, $R^2 = 0.46$, OMYH = %34.85 olarak bulunmuştur. YSA 3 modelinin tahmin başarısının, YSA/R 3 modeline üstünlüğü R , R^2 ve OMYH değerlerinden görülmektedir. YSA 3'ten elde edilen

tahminleme sonuçlarına göre girdi parametreleri ile aşınma direnci arasındaki ilişkinin yüksek olduğu sonucuna varılmıştır.

- İlk yöntemle her bir performans özelliği için ayrı ayrı elde edilen YSA 1, YSA 2 ve YSA 3 modellerinin başarısı değerlendirildiğinde YSA 1'in diğer iki modele göre daha başarılı olduğu görülmüştür. Özellikle YSA 1 ve YSA 2'nin her ikisinin de kopma mukavemetini tahminleyen modeller olmasına rağmen, YSA 1'in daha başarılı olması; şönil ipliklerinin atkıda kullanılması ve çözgü ipliklerinin sabit olması nedeniyle, girdi parametrelerinin çözgü yönü mukavemeti üzerinde atkı yönü mukavemeti kadar etkili olmaması gerekçesiyle açıklanmıştır.

- İkinci yöntemle her bir performans özelliği için ayrı ayrı elde edilen YSA/R 1, YSA/R 2 ve YSA/R 3 modellerinin başarısı değerlendirildiğinde ise YSA/R 3'ün başarısının, YSA/R 1 ve YSA/R 2'ye göre oldukça sınırlı kaldığı sonucuna varılmıştır.

- Son olarak çalışmada elde edilen altı adet yapay sinir ağı modellerinden, özellikle ilk yönteme göre kurulan YSA 1, YSA 2 ve YSA 3 modellerinin, belirlenen girdi parametrelerine uygun olarak, üretim yapmadan önce atkı-çözgü yönünde kopma mukavemetleri ve aşınma direncini tahminlemede güvenilir olabileceği; ikinci yönteme göre kurulan YSA/R 1, YSA/R 2 ve YSA/R 3 modellerinin ise herhangi bir girdi parametresi bilgisi olmadığı durumlarda bilgi sahibi olmak adına kullanılabileceği sonucuna varılmıştır.

Zaman kavramının her sektörde olduğu gibi tekstil sektöründe de değerli olduğu bilinciyle, belirlenen parametrelerle üretim yapıldığında nasıl sonuç alınacağını üretim öncesinde bilinmesine yönelik çalışmaların büyük avantajlar doğuracağı bu ve buna benzer çalışmalarla görülmektedir. Bu çalışmadan yola çıkılarak ileriki çalışmalar için öneriler şu şekilde olabilir:

- * Kullanılan numune sayısı artırılıp ya da girdi parametreleri çeşitlendirilebilir (örneğin farklı iplik numaraları ve farklı lif türleri ile).
- * Farklı performans özelliklerinin (boncuklanma, hava geçirgenliği gibi) incelenmesi düşünülebilir.
- * Çalışmadaki materyallerle farklı yapay zeka yöntemleri (bulanık mantık gibi) kullanılabilir.
- * Farklı fantezi iplikler kullanılarak benzer girdi ve çıktılarla çalışılabilir.

KAYNAKLAR

- Abouelela, A., et al., (2005). Automated vision system for localizing structural defects in textile fabrics. *Pattern Recognition Letters*. 26 (10), 1435–1443.
- Ahirwar, M., Behera, B.K. (2024). Prediction of tear strength of bed sheet fabric using machine learning based artificial neural network. *The Journal of The Textile Institute*. 115:1, 22-28.
- Alagirusamy, R., Das, A. (2015). Chapter 8 - Conversion of Fibre to Yarn: An Overview. Editor(s): Rose Sinclair. In Woodhead Publishing Series in Textiles, Textiles and Fashion. Woodhead Publishing. ISBN 9781845699314. 159-189.
- Alkap, M. (2019). Yapay sinir ağırları yöntemiyle talep tahmini: iplik fabrikası örneği. Yüksek Lisans Tezi. Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü. Tekstil Mühendisliği Anabilim Dalı. Kahramanmaraş.
- Almetwally, A.A., Idrees, H.M.F., Hebeish, A.A. (2014). Predicting the tensile properties of cotton/spandex core-spun yarns using artificial neural network and linear regression models. *The Journal of The Textile Institute*. 105:11, 1221–1229.
- Alibi, H., Falaya, F., Jemni, A., Zeng, X., (2012). A neural network system for prediction of thermal resistance of knit fabrics. *Special Topics and Reviews in Porous Media: An International Journal*. 3 (1).
- Amor, N., Noman, M.T., Ismail, A., Petru, M., Sebastian, N. (2022). Use of Artificial Neural Network for Tensile Strength Prediction of Nano Titanium Dioxide Coated Cotton. *Polymers*. 14, 937.
- Arıkan Kargı, V.S. (2016). Supplier Selection for A Textile Company Using The Fuzzy TOPSIS Method. *Yönetim ve Ekonomi: Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 23(3), 789-803.
- Au, K., Wong, W., Zeng, X., (2006). Decision model for country site selection of overseas clothing plants. *The International Journal of Advanced Manufacturing Technology*. 29 (3–4), 408–417.
- Au, K.-F., Choi, T.-M., Yu, Y., (2008). Fashion retail forecasting by evolutionary neural networks. *International Journal of Production Economics*. 114 (2), 615–630.
- Babaarslan, O., Telli, A., (2013). Şönül İpliklerin Denim Kumaş Üretiminde Kullanılabilirliği Üzerine Bir Çalışma. *Tekstil ve Mühendis*. 20 (92), 1-10.
- Bahlmann, C., Heidemann, G., Ritter, H., (1999). Artificial neural networks for automated quality control of textile seams. *Pattern Recognition*. 32 (6), 1049–1060.
- Beale, M.H., Hagan, M.T., Demuth, H.B., (2018). Neural Network Toolbox™ Getting Started Guide.
- Beale, M.H., Hagan, M.T., Demuth, H.B., (2023). Deep Learning Toolbox™ User's Guide.
- Behera, B., Mishra, R., (2007). Artificial neural network-based prediction of aesthetic and functional properties of worsted suiting fabrics. *International Journal of Clothing Science and Technology*. 19 (5), 259–276.

- Beltran, R., Wang, L., Wang, X., (2005). Predicting the pilling propensity of fabrics through artificial neural network modeling. *Textile Research Journal*. 75 (7), 557–561.
- Bhattacharjee, D., Kothari, V.K., (2007). A neural network system for prediction of thermal resistance of textile fabrics. *Textile Research Journal*. 77 (1), 4–12.
- Bilişik, K., Demiryürek, O. (2011). Analysis and tensile-tear properties of abraded denim fabrics depending on pattern relations using statistical and artificial neural network models. *Fibers and Polymers*. 12, 422–430.
- Brad, R., HĂloi, E., Brad, R. (2015). Seam Puckering Objective Evaluation Method for Sewing Process. *Annals of the University of Oradea. Fascicle of Textiles, Leatherwork*. XV.
- Carbonneau, R., Laframboise, K., Vahidov, R., (2008). Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research*. 184 (3), 1140–1154.
- Chandra, C., Kumar, S., (2000). An application of a system analysis methodology to manage logistics in a textile supply chain. *Supply Chain Management: An International Journal*. 5 (5), 234–245.
- Chandra, J.K., Banerjee, P.K., Datta, A.K., (2010). Neural network trained morphological processing for the detection of defects in woven fabric. *The Journal of the Textile Institute*. 101 (8), 699–706.
- Chatbri, H., Jemmali, S., Hannachi, S. (2019). Empowering the Tunisian textile industry with artificial intelligence.
- Chen, R.-C., Li, S.-S., Lin, C.-C., Feng, C.-C. (2005). A GA-Based Global Decision Support System for Garment Production. In: *Proceedings of the Fourth International Conference on Information and Management Sciences*.
- Chen, Y., Zeng, X., Happiette, M., Bruniaux, P., Ng, R., Yu, W. (2006). Estimation of Ease Allowance of a Garment using Fuzzy Logic. In: Kahraman, C. (eds) *Fuzzy Applications in Industrial Engineering. Studies in Fuzziness and Soft Computing*, vol 201. Springer, Berlin, Heidelberg. 367–379.
- Chen, Y., Zeng, X., Happiette, M., Bruniaux, P., Ng, R., Yu, W., (2009). Optimisation of garment design using fuzzy logic and sensory evaluation techniques. *Engineering Applications of Artificial Intelligence*. 22 (2), 272–282.
- Chen, Y., Zhao, T., Collier, B., (2001). Prediction of fabric end-use using a neural network technique. *Journal of the Textile Institute*. 92 (2), 157–163.
- Chiu, M., Lin, G., (2004). Collaborative supply chain planning using the artificial neural network approach. *Journal of Manufacturing Technology Management*. 15 (8), 787–796.
- Choy, K.L., et al., (2009). A RFID-case-based sample management system for fashion product development. *Engineering Applications of Artificial Intelligence*. 22 (6), 882–896.

- Cui, P., Xue, Y., (2020). Texture features extraction of multi-coloured fancy yarn. *Industria Textila*. 71 (6), 562-567.
- Çelik, H. İ., Dülger, L. C., Öztaş, B., Kertmen, M., Gültekin, E. (2022). A Novel Industrial Application of CNN Approach: Real Time Fabric Inspection and Defect Classification on Circular Knitting Machine. *Textile and Apparel*. 32(4), 344-352.
- Çelik, H., Topalbekiroğlu, M., Dülger, L. (2015). Real-Time Denim Fabric Inspection Using Image Analysis. *Fibres and Textiles in Eastern Europe*. 23. 85-90.
- Çeven, E.K., Özdemir, Ö. (2006). A Study of the Basic Parameters Describing the Structure of Chenille Yarns. *Fibres & Textiles in Eastern Europe*. 14, 2(56), 24-28.
- Çeven, E. K., Özdemir, Ö., (2007). Using fuzzy logic to evaluate and predict chenille yarn's shrinkage behaviour. *Fibres & Textiles in Eastern Europe*. 15(3), 55-59.
- Çeven, E. K., Şardağ, S. (2017). "Fantazi ipliklere uygulanan kalite kontrol testleri". *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*. 22(1), 1-12.
- Çeven, E.K., Tokat, S., Özdemir, Ö., (2007). Prediction of chenille yarn and fabric abrasion resistance using radial basis function neural network models. *Neural Computing and Applications*. 16, 139–145.
- Das, S., Shanmugavelu, S., Aiswarya, M., Jayaram, S. (2021). Deep Learning Convolutional Neural Network for Defect Identification and Classification in Woven Fabric. *Indian Journal of Artificial Intelligence and Neural Networking*. 1(2).
- Ding, Y., Xu, Y., (2008). Intelligent optimal selection of garment sizes by using immune algorithm and AHP method. *Journal of the Textile Institute*. 99 (3), 281–286.
- Dong, A., Leung, S., (2009). A simulation-based replenishment model for the textile industry. *Textile Research Journal*. 79 (13), 1188–1201.
- El-Geiheini, A., ElKateb, S., Abd-Elhamied, M.R. (2020). Yarn Tensile Properties Modeling Using Artificial Intelligence. *Alexandria Engineering Journal*. 59 (6), 4435-4440.
- Erem, A.D. (2006). Döşemelik kumaşların kullanım performanslarını ve aşınma dayanımlarını etkileyen şönil iplik parametrelerinin incelenmesi. Yükzek Lisans Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Tekstil Mühendisliği Ana Bilim Dalı. İstanbul.
- Erenler, A. (2013). Giysi amaçlı dokunmuş kumaşlarda konfor özelliklerinin incelenmesi ve tahminlenmesi. Doktora Tezi. Çukurova Üniversitesi Fen Bilimleri Enstitüsü. Tekstil Mühendisliği Anabilim Dalı. Adana.
- Esi, B., Baykal, P.D., (2022). Optimization of the Yarn Slippage at the Seam in Chenille Upholstery Fabrics Including Recycled and Virgin Polyester Yarns. *Textile and Apparel*. 32(1), 1-8.

- Evans, J.D. (1996) *Straightforward Statistics for the Behavioral Sciences*. Brooks/Cole Publishing; Pacific Grove, Calif.
- Farber, R. (2011). *CUDA Application Design and Development*. Chapter 2 - CUDA for Machine Learning and Optimization. Editor(s): Rob Farber, Morgan Kaufmann. 33-61.
- Fausett, L. (1994). *Fundamentals of neural networks*. New Jersey, NJ: Prentice Hall.
- Fouda, A., Těšinová, P., Khalil, A., Eldeeb, M. (2021). Thermo-physiological properties of polyester chenille single Jersey knitted fabrics. *Alexandria Engineering Journal*. 61(9), 7029-7036.
- Fumi, A., Pepe, A., Scarabotti, L., Schiraldi, M., (2013). Fourier analysis for demand forecasting in a fashion company. *International Journal of Engineering Business Management*. 5, 30.
- Goode, M.M., Davies, F., Moutinho, L., Jamal, A., (2005). Determining customer satisfaction from mobile phones: a neural network approach. *Journal of Marketing Management*. 21 (7–8), 755–778.
- Groves, G., Valsamakis, V., (1998). Supplier-customer relationships and company performance. *The International Journal of Logistics Management*. 9 (2), 51–64.
- Guo, Z.X., Wong, W.K., Leung, S.Y.S., Fan, J.T., Chan, S.F., (2008). Genetic optimization of order scheduling with multiple uncertainties. *Expert Systems with Applications*. 35 (4), 1788–1801.
- Gültekin, E., Çelik, H.İ., Nohut, S., Karakurd Elma, S. (2020). Predicting air permeability and porosity of nonwovens with image processing and artificial intelligence methods. *The Journal of The Textile Institute*. 111 (11), 1641-1651.
- Gürgen, G. (2019). Derin öğrenme ile tekstil tipi tanıma. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü. Elektronik ve Haberleşme Mühendisliği Anabilim Dalı. İstanbul.
- Hsu, C., Lee, T., Kuo, H., (2009). Applying fuzzy theory based data mining to establish the female sizing systems for garment production. In: *Proceedings of the 8th WSEAS International Conference on Applied Computing and Applied Computational Science*, Hangzhou, China, World Scientific and Engineering Academy and Society.
- Huang, C.-C., Chen, I.-C., (2001). Neural-fuzzy classification for fabric defects. *Textile Research Journal*. 71 (3), 220–224.
- Hui, C., Ng, S., (2005). A new approach for prediction of sewing performance of fabrics in apparel manufacturing using artificial neural networks. *Journal of the Textile Institute*. 96 (6), 401–405.
- Hui, C.L., Lau, T.W., Ng, S.F., Chan, K.C.C., (2004). Neural network prediction of human psychological perceptions of fabric hand. *Textile Research Journal*. 74 (5), 375–383.

- Hui, C.L., Ng, S.F., (2009). Predicting seam performance of commercial woven fabrics using multiple logarithm regression and artificial neural networks. *Textile Research Journal*. 79 (18), 1649–1657.
- Hui, P.C., et al., (2007). Application of artificial neural networks to the prediction of sewing performance of fabrics. *International Journal of Clothing Science and Technology*. 19 (5), 291–318.
- Inui, S., (1996). A combined system of computer aided design and genetic algorithm for apparel designing. *Sen'i Gakkaishi*. 52 (11), 605–611.
- İlhan, İ., (2017). An experimental investigation on strength and elongation properties of chenille yarn. *Tekstik Ve Konfeksiyon*. 27(2), 117-125.
- İlhan, İ., Yarar, A.Y., (2015). Predicting twist contraction in chenille yarn using mathematical and statistical approaches. *The Journal of The Textile Institute*. 107 (9), 1185-1192.
- Jasper, W.J., Kovacs, E.T., Berkstresser IV, G.A., (1993). Using neural networks to predict dye concentrations in multiple-dye mixtures. *Textile Research Journal*. 63 (9), 545–551.
- Jing, J., Liu, S., Li, P., Zhang L. (2016). The fabric defect detection based on CIE L* a* b* color space using 2-D Gabor filter. *The Journal of The Textile Institute*. 107 (10), 1305-1313.
- Jing, J., Xu, M., Li, P., Li, Q, Liu, S. (2014). Automatic classification of woven fabric structure based on texture feature and PNN. *Fibers and Polymers*. 15, 1092–1098.
- Kalınlı, A. (2002). Elman Ağının Simulated Annealing Algoritması Kullanarak Sistem Kimliklendirme İçin Eğitilmesi. *Eskişehir Osmangazi Üniversitesi Mühendislik Ve Mimarlık Fakültesi Dergisi*. 15(2), 25-42.
- Kalkancı, M., Kurumer, G., Öztürk, H., Sinecen, M., Kayacan, Ö. (2017). Artificial Neural Network System for Prediction of Dimensional Properties of Cloth in Garment Manufacturing: Case Study on a T-Shirt. *Fibres & Textiles in Eastern Europe*. 25, 4(124): 135-140.
- Kalkınma Ajansları Genel Müdürlüğü, (2021). COVID-19 Krizine Yanıt ve Dayanıklılık Projesi Tekstil Sektörü Analiz Raporu ve Kılavuzu-TR32 Bölgesi. ISBN: 978-605-7679-09-3
- Kavuştur, Y., Çeven, E.K., Özdemir, Ö., (2010). "Effect of chenille yarns produced with selected comfort fibres on the abrasion and bending properties of knitted fabrics". *Fibres and Textiles in Eastern Europe*. 18(1), 48-53.
- Kim, E.H., (1999). Objective evaluation of wrinkle recovery. *Textile Research Journal*. 69 (11), 860–865.
- Kim, H., Jung, W.-K., Park, Y.-C., Lee, J.-W., Ahn, S.-H. (2022). Broken stitch detection method for sewing operation using CNN feature map and image-processing techniques. *Expert Systems with Applications*. 188, 116014.

- Kim, H.-S., Cho, S.-B., (2000). Application of interactive genetic algorithm to fashion design. *Engineering Applications of Artificial Intelligence*. 13 (6), 635–644.
- Koehl, L., Zeng, X., Camargo, M., Fonteix, C., Delmotte, F., (2008). Analysis and identification of fashion oriented industrial products using fuzzy logic techniques. In: 3rd International Conference on Intelligent System and Knowledge Engineering, 2008. ISKE 2008. IEEE.
- Kotb, N.A. (2019). Predicting Yarn Quality Performance Based on Fibers types and Yarn Structure. *Life Science Journal*. 9(3), 1009-1015
- Kothari, V.K., Bhattacharjee, D. (2011). Artificial neural network modelling for prediction of thermal transmission properties of woven fabrics. *Soft Computing in Textile Engineering*. Woodhead Publishing Limited, New York, NY. 403-423.
- Kulkarni, K.M., Sahu, A.R. (2022). Brief Overview on Study of Various Parameters Affecting the Productivity of Cotton Yarn. *Smart Technologies for Energy, Environment and Sustainable Development*. Vol 1, 955-963.
- Kumar, A., (2003). Neural network based detection of local textile defects. *Pattern Recognition*. 36 (7), 1645–1659.
- Lewis, C.D. (1982). *Industrial and business forecasting methods*. London: Butterworths.
- Li, S.Y., Xu, B.G., Fu, H., Tao, X.M., Chi, Z.R. (2018). A two-scale attention model for intelligent evaluation of yarn surface qualities with computer vision. *The Journal of Textile Institute*. 109, 798-812.
- Liang, Z., Xu, B., Chi, Z., Feng, D. (2012). Intelligent characterization and evaluation of yarn surface appearance using saliency map analysis, wavelet transform and fuzzy ARTMAP neural network. *Expert Systems with Applications*. 39, 4201-4212.
- Lin, J.-J., (2007). Intelligent decision making based on GA for creative apparel styling. *Journal of Information Science and Engineering*. 23 (6).
- Lo, W.-S., Hong, T.-P., Jeng, R., (2008). A framework of E-SCM multi-agent systems in the fashion industry. *International Journal of Production Economics*. 114 (2), 594–614.
- Luo, X., Hou, W., Li, Y., Wang, Z., (2007). A fuzzy neural network model for predicting clothing thermal comfort. *Computers and Mathematics with Applications*. 53 (12), 1840–1846.
- Majumdar, A., Ghosh, A., Saha, S. Roy, A., Barman, S., Panigrahi, D., Biswas, A. (2008). Empirical modelling of tensile strength of woven fabrics. *Fibers and Polymers*. 9, 240-245.
- Mak, K., Li, W., (2008). Objective evaluation of seam pucker on textiles by using self-organizing map. *IAENG International Journal of Computer Science*. 35 (1), 47–54.

- Midha, V.K., Kothari, V.K., Chattopadhyay, R., Mukhopadhyay, A. (2010). A neural network model for prediction of strength loss in threads during high speed industrial sewing. *Fibers and Polymers*. 11, 661–668.
- Moezzi, M., Ghane, M., Semnani, D. (2015). Predicting the Tensile Properties of UV Degraded Nylon66/Polyester Woven Fabric Using Regression and Artificial Neural Network Models. *Journal of Engineered Fibers and Fabrics*. 10, 1–11.
- Montaño Moreno, J.J., Palmer Pol, A., Sesé Abad, A., Cajal Blasco, B. (2013). Using the R-MAPE index as a resistant measure of forecast accuracy. *Psicothema*. 25(4), 500-506.
- Mori, T., Komiyama, J., (2002). Evaluating wrinkled fabrics with image analysis and neural networks. *Textile Research Journal*. 72 (5), 417–422.
- Muni, D.P., Pal, N.R., Das, J., (2006). Texture generation for fashion design using genetic programming. In: Control, Automation, Robotics and Vision, 2006. ICARCV'06. 9th International Conference on. 2006. IEEE.
- Nawaz, N., Nayak, R., (2015). Seamless garments. In: Nayak, R., Padhye, R. (Eds.), *Garment Manufacturing Technology*. Cambridge, UK, 373–383.
- Nayak, R., Padhye, R., Gon, D.P., (2010). Sewing performance of stretch denim. *Journal of Textile and Apparel, Technology and Management*. 6 (3), 1–9.
- Nayak, R., Padhye, R., (2018). 5 - Artificial intelligence and its application in the apparel industry. Editor(s): Rajkishore Nayak, Rajiv Padhye. In *The Textile Institute Book Series, Automation in Garment Manufacturing*. Woodhead Publishing, ISBN 9780081012116. 109-138.
- Nazir, M.K., Ghani, M.A.N.U., Ashraf, A., Alam, S.M., Farooq, R.U., Latif, Z. (2021). A Textile Image Classification based on Texture and Shape Features. 2021 International Conference on Innovative Computing (ICIC), Lahore, Pakistan. 1–6.
- Ngai, E.W., Xiu, L., Chau, D.C., (2009). Application of data mining techniques in customer relationship management: a literature review and classification. *Expert Systems with Applications*. 36 (2), 2592–2602.
- Ngan, H.Y.T., Pang, G.K.H., Yung, S.P., Ng, M.K., (2005). Wavelet based methods on patterned fabric defect detection. *Pattern Recognition*. 38 (4), 559–576.
- Ngan, H.Y.T., Pang, G.K.H., Yung, N.H.C., (2011). Automated fabric defect detection-a review. *Image and Vision Computing*. 29 (7), 442–458.
- Norton-Wayne, L., (1990). Automated garment inspection using machine vision. In: IEEE International Conference on Systems Engineering, 1990.
- Özçelik, G. (2009). Kumaş boncuklanma özelliğinin objektif olarak değerlendirilmesi ve tahminlenmesi üzerine bir araştırma. Doktora Tezi. Ege Üniversitesi Fen Bilimleri Enstitüsü. Tekstil Mühendisliği Anabilim Dalı. İzmir.

- Öztaş, B., Korkmaz, Y., Çelik, H.İ. (2024). Image analyses of artificially damaged carbon/glass/epoxy composites before and after impact load. *Heliyon*. 10(4), e25876.
- Pan, A., Leung, S.Y.S., Moon, K.L., Yeung, K.W., (2009). Optimal reorder decision-making in the agent-based apparel supply chain. *Expert Systems with Applications*. 36 (4), 8571–8581.
- Pan, R., Gao, W., Li, W., Xu, B. (2017). Image analysis for seam-puckering evaluation. *Textile Research Journal*. 87(20), 2513-2523.
- Park, S.-W., Hwang, Y.-G., Kang, B.-C., Yeo, S.-W., (2000). Applying fuzzy logic and neural networks to total hand evaluation of knitted fabrics. *Textile Research Journal*. 70 (8), 675–681.
- Papageorgiou, S. (2022). On correlation coefficients and their interpretation. *Journal of Orthodontics*. 49. 359-361.
- Paul, S., Azeem, A., (2011). An artificial neural network model for optimization of finished goods inventory. *International Journal of Industrial Engineering Computations*. 2 (2), 431–438.
- Principe, J.C., Euliano, N. R., Lefebvre, W.C. (1999). Neural and adaptive systems. New York, NY: Wiley.
- Rajamanickam, R., Hansen, S., Jayaraman, S. (1997). Analysis of the modeling methodologies for predicting the strength of air-jet spun yarns. *Textile Research Journal*. 67, 39-44.
- Rolich, T., Šajatović, A.H., Pavlinić, D.Z. (2010). Application of artificial neural network (ANN) for prediction of fabrics' extensibility. *Fibers and Polymers*. 11, 917–923.
- Sarkar, J., Al Faruque, M.A., Mondal, M.S. (2021). Modeling the seam strength of denim garments by using fuzzy expert system. *Journal of Engineered Fibers and Fabrics*. 16.
- Seçkin, A.Ç., Seçkin, M., (2022). Detection of fabric defects with intertwined frame vector feature extraction. *Alexandria Engineering Journal*. 61 (4), 2887-2898.
- Sengupta, A., Roy, S., Sengupta, S. (2015). Development of a low cost yarn parameterisation unit by image processing. *Measurement*. 59, 96-109.
- Senthilkumar, M., Selvakumar, N., (2006). Achieving expected depth of shade in reactive dye application using artificial neural network technique. *Dyes and Pigments*. 68 (2), 89–94.
- Shady, E., Yasser, G., Abouiiiana, M., Youssef, S., Pastore, C. (2006). Detection and classification of defects in knitted fabric structures. *Textile Research Journal*. 76 (4), 295–300.

- Shaik, N.B., Pedapati, S.R., Taqvi, S.A.A., Othman, A.R., Dzubir, F.A.A. (2020). A Feed-Forward Back Propagation Neural Network Approach to Predict the Life Condition of Crude Oil Pipeline. *Processes*. 8, 661.
- Shamey, R., Hussain, T., (2003). Artificial intelligence in the colour and textile industry. *Review of Progress in Coloration and Related Topics*. 33 (1), 33–45.
- Shin, Y., Kim, Y., Kim, E.Y. (2010). Automatic textile image annotation by predicting emotional concepts from visual features. *Image and Vision Computing*. 28, 3, 526-537.
- Sun, Z.-L., Choi, T.-M., Au, K.-F., Yu, Y., (2008). Sales forecasting using extreme learning machine with applications in fashion retailing. *Decision Support Systems*. 46 (1), 411–419.
- Süle, İ., (2014). The determination of the twist level of the Chenille yarn using novel image processing methods: Extraction of axial grey-level characteristic and multi-step gradient based thresholding. *Digital Signal Processing*. 29, 78-99.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A., (2014). Going Deeper with Convolutions. *Computing Research Repository (CoRR)*. abs/1409.4842.
- Şengöz, N. (2016). Yapay zeka metotlarının bir sınıflandırma probleminde karşılaştırılması. Yükzek Lisans Tezi. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Ana Bilim Dalı. Isparta.
- Talu, M.F., Hanbay, K., Varjovi, M.H. (2022). CNN-based fabric defect detection system on loom fabric inspection. *Tekstil ve Konfeksiyon*. 32(3), 208-219.
- Tekeoğlu, O., Kavuşturan, Y., (2011). Şenil ve Makarna Döşemelik Kumaşların Aşınma Dayanımı ve Kopma Mukavemeti. *Tekstil ve Konfeksiyon*. 21, 4, 336–342.
- Tilocca, A., Borzone P, Carosio S, Durante A., (2002). Detecting fabric defects with a neural network using two kinds of optical patterns. *Textile Research Journal*. 72 (6), 545–550.
- Tsai, I.-S., Hu, M.-C., (1996). Automatic inspection of fabric defects using an artificial neural network technique. *Textile Research Journal*. 66 (7), 474–482.
- Tunak, M., Bajzik, V., Testik, M.C., (2011). Monitoring chenille yarn defects using image processing with control charts. *Textile Research Journal*. 81(13), 1344-1353.
- URL1. (erişim tarihi: 16.04.2024) <https://medium.com/deep-learning-turkiye/derin-%C3%B6C4%9Frenme-mimarileri-deep-learning-architectures-9d9429c485b9>
- URL2. (erişim tarihi: 16.04.2024) <https://www.oracle.com/tr/artificial-intelligence/machine-learning/what-is-deep-learning/>
- URL3. (erişim tarihi: 23.10.2023) https://www.mathworks.com/help/deeplearning/ref/googlenet.html?searchHighlight=googlenet&s_tid=srchtitle_support_results_1_googlenet

- URL4. (erişim tarihi: 23.10.2023) https://www.mathworks.com/help/deeplearning/ref/alexnet.html?searchHighlight=alexnet&s_tid=srchtitle_support_results_1_alexnet
- URL5. (erişim tarihi: 23.10.2023) <https://towardsdatascience.com/the-w3h-of-alexnet-vggnet-resnet-and-inception-7baaaecccc96>
- URL6. (erişim tarihi: 11.07.2024) <https://www.slideshare.net/minemithat/tks444-2>
- URL7. (erişim tarihi: 01.01.2024) <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4>
- Ünal, P.G., Üreyen, M.E., Mecit, D., (2012). Predicting properties of single jersey fabrics using regression and artificial neural network models. *Fibers and Polymers*. 13 (1), 87–95.
- Wang, Z., Li, Y., Wong, A.S.W., (2005). Simulation of clothing thermal comfort with fuzzy logic. Elsevier Ergonomics Book Series. 3, 467–471.
- Wong, A.S.W., Li, Y., Yeung, P.K.W., (2004). Predicting clothing sensory comfort with artificial intelligence hybrid models. *Textile Research Journal*. 74 (1), 13–19.
- Wong, A.S.W., Li, Y., Yeung, P.K.W., Lee, P., (2003). Neural network predictions of human psychological perceptions of clothing sensory comfort. *Textile Research Journal*. 73 (1), 31–37.
- Wong, W., Leung, S., Au, K., (2005). Real-time GA-based rescheduling approach for the pre-sewing stage of an apparel manufacturing process. *The International Journal of Advanced Manufacturing Technology*. 25(1–2), 180–188.
- Wong, W.K., Yuen, C.W.M., Fan, D.D., Chan, L.K., Fung, E.H.K. (2009). Stitching defect detection and classification using wavelet transform and BP neural network. *Expert Systems with Applications*. 36 (2), 3845–3856.
- Xia, M., Zang, Y., Weng, L., Ye, X., (2012). Fashion retailing forecasting based on extreme learning machine with adaptive metrics of inputs. *Knowledge-Based Systems*. 36, 253–259.
- Xiao, Q., Wang, R., Zhang, S., Li, D., Sun, H., Wang, L. (2020). Prediction of pilling of polyester–cotton blended woven fabric using artificial neural network models. *Journal of Engineered Fibers and Fabrics*. 15.
- Vadood, M., Haji, A. (2022). A hybrid artificial intelligence model to predict the color coordinates of polyester fabric dyed with madder natural dye. *Expert Systems with Applications*. 193, 116514.
- Yapi, D., Mejri, M., Allili, M.S., Baaziz, N., (2015). A learning-based approach for automatic defect detection in textile images. *IFAC-PapersOnLine*. 48 (3), 2423–2428.

- Yaşar Çıklaçandır, F.G., Utku, S., Özdemir, H. (2023). The effects of fusion-based feature extraction for fabric defect classification. *Textile Research Journal*. 93(23-24), 5448–5460.
- Yıldız, K., (2019). Identification of wool and mohair fibres with texture feature extraction and deep learning. *The Institution of Engineering and Technology*. 14 (2), 348-353.
- Yıldız, Z., Dal, V., Ünal, M., Yıldız, K., (2013). Use of artificial neural networks for modelling of seam strength and elongation at break. *Fibres and Textiles in Eastern Europe*. 101 (5), 117–123.
- Youn, S., Knowles, C. G., Mills, A. C., Mathur, K. (2024). Comparative study of physical and virtual fabric parameters: physical versus virtual drape test using commercial 3D garment software. *The Journal of The Textile Institute*. 116(1), 33–46.
- Yu, Y., Choi, T.-M., Hui, C.-L., (2011). An intelligent fast sales forecasting model for fashion products. *Expert Systems with Applications*. 38 (6), 7373–7379.
- Yuen, C.W.M., Fung, E.H.K., Wong, W.K., Hau, L.C., Chan, L.K., (2008). Application of smart system to textile industry: preliminary design of a smart hanger for garment inspection. *Journal of the Textile Institute*. 99 (6), 569–580.
- Yuen, C.W.M., Wong, W.K., Qian, S.Q, Chan, L.K., Fung, E.H.K., (2009a). A hybrid model using genetic algorithm and neural network for classifying garment defects. *Expert Systems with Applications*. 36 (2), 2037–2047.
- Yuen, C.W.M., Wong, W.K., Qian, S.Q, Fan, D.D., Chan, L.K., Fung, E.H.K., (2009b). Fabric stitching inspection using segmented window technique and BP neural network. *Textile Research Journal*. 79 (1), 24–35.
- Zeydan, M. (2008). Modelling the woven fabric strength using artificial neural network and Taguchi methodologies. *International Journal of Clothing Science and Technology*. 20(2):104-118.
- Zhang, J., Yang, C. (2014). Evaluation model of color difference for dyed fabrics based on the support vector machine. *Textile Research Journal*. 84(20), 2184-2197.
- Zhao, X., Shi, X., Liu, K., Deng, Y., (2019). An intelligent detection and assessment method based on textile fabric image feature. *International Journal of Clothing Science and Technology*. <https://doi.org/10.1108/IJCST-01-2018-0005>