

BOYANMIŞ KUMAŞLARDA KİMYASAL APRE UYGULAMALARI SONUCUNDA OLUŞABİLECEK RENK DEĞİŞİMİNİN VE CIELab DEĞERLERİNİN YAPAY SİNİR AĞLARI KULLANILARAK TAHMİN EDİLMESİ

PREDICTION OF CIELab VALUES AND COLOR CHANGING OCCURRED AFTER CHEMICAL FINISHING APPLICATIONS BY ARTIFICIAL NEURAL NETWORKS ON DYED FABRICS

Onur BALCI

Çukurova Üniversitesi, Tekstil Mühendisliği Bölümü

R. Tuğrul OĞULATA

Çukurova Üniversitesi, Tekstil Mühendisliği Bölümü

e-mail: ogulata@cu.edu.tr

ÖZET

Renk, hammaddenin özelliğinden, son apre işlemine kadar, üretimin her aşamasından etkilenen bir olgudur. Özellikle kimyasal apre uygulamaları sonucunda oluşan renk farklılığı önemli sorunlar yaratmaktadır. Çalışmada seçilen altı farklı dokunmuş ve renklendirilmiş kumaşın apre işlemlerinin CIELab değerlerine etkisi, dolayısıyla renklerinde meydana gelen değişimler (ΔL^* , Δa^* , Δb^* , ΔC^* , ΔH^* , ΔE) belirlenmiş ve daha sonra bu değerler farklı topolojilerde yapay sinir ağları (YSA) kullanılarak tahmin edilmeye çalışılmıştır. Yapılan çalışma sonucunda kurulan YSA modellerinin, apre uygulamaları ve diğer üretim proseslerine bağlı olarak, boyanmış kumaşa meydana gelebilecek renk değişimlerinin tahmininde kullanılabileceğini göstermektedir.

Anahtar Kelimeler: Kimyasal apre, CIELab, Renk, Yapay sinir ağları, Tahmin.

ABSTRACT

Color is a fact affected from the properties of the raw material to the final finishing processes which are the most important ones. In the study, the effect of the finishing processes to CIELab values, consequently the changing on the color were determined, and then these values were tried to be predicted using artificial neural networks (ANN) on different topology. In this way, the color changing concerning on chemical finishing process can be determined in advance and the necessary precaution can be taken without having trouble by changes on the dyeing recipes and process parameters.

Key Words: Chemical finishing, CIELab, Color, Artificial neural network, Prediction.

Received: 01.04.2008

Accepted: 31.08.2008

1. GİRİŞ

YSA, insan beyninin en temel özelliği olan öğrenme fonksiyonunu gerçekleştiren bilgisayar sistemleridir. Öğrenme işlemini örnekler yardımı ile gerçekleştirirler. Bu ağlar birbirine bağlı proses elemanlarından oluşur. Her bağlantının bir ağırlık değeri vardır. Yapay sinir ağının sahip olduğu bilgi bu ağırlık değerlerinde saklı olup ağa yayılmıştır (1).

Birçok yapay sinir ağı tipi bulunmakla birlikte bazılarının kullanımı diğerlerinden daha yaygındır. En çok kullanılan yapay sinir ağı ise, çok katmanlı yapay sinir ağı olarak bilinendir (2). Çok katmanlı yapay sinir ağları ileri beslemeli ağlardır ve öğretmenli öğrenme stratejisine göre çalışırlar.

İleri beslemeli ağlar, katmanlı yapıya sahiptir. Her bir katman, bir önceki katmandaki girişleri alan ve kendi çıktılarını bir sonraki katmanda bulunan nöronlara gönderen nöronlardan oluşur. Ağın görevi her girdi için o girdiye karşılık gelen çıktıyı üretmektir. Giriş katmanından alınan girişler, giriş katmanı ve gizli katman arasında bulunan bağlantı ağırlıkları ile çarpılıp gizli katmana iletilir. Gizli katmandaki sinirlere gelen girişler toplanarak aynı şekilde gizli katman ile çıkış katmanı arasındaki ağırlıklarla çarpılarak çıkış katmanına iletilir. Çıkış katmanındaki sinirler de kendisine gelen bu girişleri toplayarak buna uygun bir çıkış üretirler. Aktivasyon fonksiyonu, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler.

Uygulamaların çoğunda, çok katmanlı ağlar tek gizli katmanlı olarak oluşturulmakta ve aktivasyon fonksiyonu olarak da sigmoid fonksiyon kullanılmaktadır (3).

Yapay sinir ağlarında, öğrenme çok önemli bir özelliktir. Öğrenme sürecinin amacı çıkış nöronundaki istenilen değer ile ağın değeri arasındaki farkın karesini minimize etmektir. Bu amaca da, bağlantı ağırlıklarının ayarlanması ile ulaşılır. Ağırlıklarının ayarlanması değişik öğrenme algoritmaları ile yapılır. Çok katmanlı yapay sinir ağları için en popüler öğrenme algoritmalarından birisi genişletilmiş delta kuralıdır (4). Bu çalışmada, öğrenme algoritması olarak genişletilmiş delta kuralı kullanılmıştır.

Genelleştirilmiş delta kuralına göre eğitim iki safhadan oluşur. Bunlar;

- 1) İleri doğru hesaplama: Ağın çıktısını hesaplama safhasıdır,
- 2) Geri doğru hesaplama: Ağırlıkları değiştirme safhasıdır.

Eğitim süreci rasgele bağlantı ağırlıkların atanması ile başlar. Çok katmanlı ağdaki gizli katmandaki j indisli her bir nöron, x_i giriş işaretini bağlantının ağırlığı w_{ji} ile çarptıktan sonra toplar ve y_j çıkışını toplamın fonksiyonu olarak şu şekilde hesaplar:

$$y_j = f(\sum w_{ji} x_i) \quad (1)$$

burada, f aktivasyon fonksiyonudur. Çıkış nöronunun istenilen değeri ve gerçek değeri arasındaki farkın toplamının karesi E şu şekilde ifade edilir:

$$E = \frac{1}{2} \sum (y_{kj} - y_j)^2 \quad (2)$$

burada, y_{kj} j indisli çıkış nöronunun istenilen değeri ve y_j bu çıkış nöronunun gerçek değeridir.

Genişletilmiş delta kuralına göre, k 'inci iterasyondaki i ve j indisli nöronlar arasında mevcut olan bağlantıdaki değişim şu şekilde güncellenir:

$$\Delta W_{ij}(k) = -\eta \frac{\partial E}{\partial W_{ij}} + \mu \Delta W_{ij}(k-1) \quad (3)$$

burada, η öğrenme katsayısı, μ momentum katsayısıdır (5).

İleri ve geri safhalar, ağın ortalama hatası önceden belirlenmiş bir değer altına düşünceye ya da maksimum iterasyona ulaşıncaya kadar tekrarlanır.

Yapılan incelemede tekstil endüstrisi içinde YSA'nın 90'lı yıllardan günümüze kadar farklı dallarda kullanıldığı tespit edilmiştir. YSA tekstilde genel olarak beş farklı alanda uygulama bulmuştur. Bunlar,

1. YSA ile tahminleme özellikle iplik teknolojisinde yaygın olarak kullanılmıştır. Bunlardan en önemlileri, hammadde özelliklerinin girdi (HVI), iplik performans özelliklerinin (kopma mukavemeti, tüylülük, vs..) çıktı olarak kullanıldığı çalışmalardır. Bu çalışmaların yanında yapay sinir ağları ile regresyon modellerinin tahmin güvenilirliğinin karşılaştırdığı deneysel çalışmalara da rastlanmıştır (6–15).
2. Tekstil materyallerinin sınıflandırılması ve hata tanımlaması için YSA kullanımını, sık rastlanan uygulamalar arasındadır (16–19).

3. Kumaş (örgü, sıklık vs.) ve kumaşı oluşturan iplik (numara, büküm vs.) konstrüktif özelliklerinin girdi ve kumaş fiziksel ve kimyasal performans kriterlerinin (mukavemet, pilling, aşınma dayanımı, çekmezlik vb.) çıktı olarak kullanıldığı çalışmalar da tespit edilen YSA uygulamaları arasındadır (20–23).
4. Makine ayarlarının önceden belirlenmesi hususunda da YSA başvuru bir tahmin tekniği olarak göze çarpmaktadır. Örne ve dokuma makinesi ayarlarının belirlenmesi, boyama şartlarının tespiti için kullanıldığı belirlenmiştir (24–25).
5. YSA, boyama teknolojisinde evrensel olarak reçete tahmininde kullanılan Kubelka-Munk teknolojisine alternatif olarak kullanılmıştır. Bu tür çalışmalarda boyarmadde çözeltilerinin veya açılım boyamalarının reflektans değerleri girdi olarak kullanılmış ve boyama reçeteleri tespit edilmeye çalışılmıştır (26–31).

Bu çalışmada YSA, daha karmaşık girdiler aracılığıyla tahmin yapmak üzere kullanılmaya çalışılmıştır. Önceki çalışmalardan daha ileri olarak elyafın, apre prosesinin çalışma parametrelerine kadar, geniş bir girdi yelpazesi için ağlar kurulmuştur. Bu girdilere bağlı olarak kumaştaki renk değişimi YSA modelleri kullanılarak tahmin edilmeye çalışılmıştır. Ayrıca çalışmada, en iyi performansa sahip ağın kurulabilmesi için de bazı YSA parametreleri (öğrenme oranı, momentum katsayısı, gizli katman sayısı, katmandaki düğüm sayısı) üzerinde de deneysel tasarım yöntemi ile incelemeler yapılmıştır.

2. MATERYAL VE YÖNTEM

2.1. Elyaf- Kumaş

Çalışmada incelenmek üzere altı farklı dokuma kumaş seçilmiştir. Bunlardan üçü polyester/viskon içerikliken, kalan üçü ise pamuk esaslı olarak belirlenmiştir. Tablo 1 ve Tablo 2'de seçilen

Tablo 1. Numune kumaşların teknik özellikleri (N1-N2-N3)

Özellik	Numuneler				
	N1	N2	N3		
Elyaf Parametreleri	Hammadde	P/V	P/V/EI.	P/V/EI.	
	Karışım Oranı (%)	%67-P %33-V	%65-P %32-V %3-EI.	%64.3-P %31.6-V %4.1-EI.	
	Elastan No (dtex)	Ç	-	-	44
İplik Parametreleri	Numara (Ne)	A	-	78	44
		Ç	17.7	18	16.2
	Büküm (α_e)	A	16	16.3	17
		Ç	4.1	4.1	4.1
Kumaş Parametreleri	Sıklık (tel/cm)	A	4.1	4.1	4.1
		Ç	23.8	28	29
	Gramaj (g/m ²)	A	21	24	23.5
	Örgü		164.7	198.2	210.5
		B 1/1	D 2/1 Z	D 2/1 Z	

P. Polyester, V.Viskon, EI.Elastan, B.Bezayağı, D.Dimi

Tablo 2. Numune kumaşların teknik özellikleri (N4-N5-N6)

Özellik	Numuneler				
	N4	N5	N6		
Elyaf Parametreleri	Hammadde	Pamuk	Pamuk/EI.	Pamuk/EI.	
	Karışım Oranı (%)	%100	%96-Pamuk %4-EI.	%88-Pamuk %12-EI.	
	Elastan No (dtex)	Ç	-	78	
İplik Parametreleri	Numara (Ne)	A	-	78	
		Ç	40	40.3	24.5
	Büküm (α_e)	A	40	23	28.5
		Ç	3.3	4.1	4.5
Kumaş Parametreleri	Sıklık (tel/cm)	A	2.3	4.5	4.5
		Ç	59	68	47.5
	Gramaj (g/m ²)	A	27	37	28
	Örgü		187	208.3	181.8
		D 2/1 S	Fantezi	D 2/1 S	

Tablo 3. Numune kumaşların boyama reçeteleri (N1-N2-N3)

Boyarmadde	Kahverengi (%)				Bordo (%)		
	A1	A	O	K	A	O	K
Dispers Boyama							
Disperse Orange 30	-	-	0.11	0.132	-	-	0.077
Disperse Yellow 141	0.2	0.51 7	0.805	0.935	0.126	0.44	0.805
Disperse Red 167	0.03 6	0.09 2	0.299	0.379	0.562	1.68	2.87
Disperse Blue 79	0.03	0.26 4	0.54	0.792	0.025	0.07 2	0.156
Reaktif Boyama							
Reactive Yellow 220	0.21	0.43 2	0.96	1.2	0.216	0.63 2	1.38
Reactive Red 136	0.06 5	0.16 2	0.287	0.33	0.372	1.69	2.7
Reactive Blue 60	0.11	0.33 7	0.684	1.08	0.031	0.1	0.225

A1-En Açık, A-Açık, O-Orta, K-Koyu

Tablo 4. Numune kumaşların boyama reçeteleri (N4-N5-N6)

Boyarmadde	Kahverengi (g/l)			Bordo (g/l)		
	A	O	K	A	O	K
Reactive Yellow 220	7.5	15	30	4	8	16
Reactive Red 136	3.5	7	14	12	24	48
Reactive Blue 60	7.5	15	30	5	10	20

A-Açık, O-Orta, K-Koyu

Tablo 5. Boyama işleminde kullanılan yardımcı kimyasal maddeler

Reçete	Görevi	Konsantrasyon (g/l)
Dispers Boyama Kimyasalları		
Asetik Asit	pH ayarlayıcı	1
Setasit PBN-2	pH tamponlayıcı	1
Setalan SWN-N	Dispergator	0.75
Breviol PAM NEU	Carrier	2
Setavin PE	Egalizatör	1
Redüktif Yıkama		
Kostik	pH ayarlayıcı	12
Hidrosülfid	Yıkama maddesi (İndirgen madde)	6
Reaktif Boyama Kimyasalları (N 1, N2, N3 için)		
Kemigol	Islatıcı	0.3
Benaquest SAD	İyon tutucu	0.1
NaCl (mutfak tuzu)	Elektrolit	65
Soda	pH ayarlayıcı	10
Kostik	pH ayarlayıcı	1.7
Reaktif Yıkama		
Exoline 3021	Yıkama maddesi	0.1
Reaktif Boyama Kimyasalları (N4, N5, N6 için)		
Primasol NF	Islatıcı	2
Sodyum Silikat (Cam suyu)	Elektrolit	70
Kostik	pH ayarlayıcı	36

numune kumaşların yapısal özellikleri belirtilmiştir. Ayrıca bu tablolarda verilen sayısal değerler ağırlık kurulmasında

elyaf-iplik-kumaş girdileri olarak kullanılmıştır.

2.2. Ön Terbiye

Ön terbiye işlemleri uygulanırken Polyester/Viskon esaslı kumaşlar beraber, Pamuklu kumaşlar beraber işlem görmüştür. Böylece numuneler arasında ön terbiye işlemlerinden kaynaklanan herhangi bir değişikliğin oluşması engellenmiştir. P/V kumaşlara (N1-N2-N3) sırasıyla yakma, yıkama, kurutma, termofikse ön işlemleri uygulanırken, pamuklu kumaşlara (N4-N5-N6) yakma, haşıl sökme, yıkama, kasar, yıkama, merserize, kurutma, termofikse işlemleri uygulanmıştır.

2.3. Boyama

Çalışmada seçilen 6 numune kumaş bordo ve kahverengi olmak üzere 2 farklı renge boyanmıştır. N1, N2, N3 numuneleri en açık, açık, orta, koyu tonlarında, N4, N5, N6 numuneleri ise açık, orta, koyu tonlarında boyanarak toplam 39 adet boyanmış numune elde edilmiştir (Tablo 3). N1-N2-N3 çektirme yöntemine göre jet boyama makinesinde boyanırken, N4-N5-N6 emdirme yöntemine göre pad-batch boyama prensine göre boyanmıştır. Boyamalar gerçekleştirildikten sonra, kumaşlar 10'ar metre şeklinde alınmış, 39 tip numune, laboratuvar şartlarında apre yapılacak boyutlarda 12 cm x 25 cm şeklinde kesilmiştir. Daha sonra her numunenin önüne astar kumaş dikilerek, apre işlemlerine hazır hale getirilmiştir. Tablo 3 ve Tablo 4'de kumaşların boyama reçeteleri verilmiştir. Tablo 5'de numunelerin boyanmasında kullanılan yardımcı kimyasallar verilmiştir.

2.4. Kimyasal Apre İşlemleri

Çalışmada boyalı numune kumaşlara makro-mikro silikon, su iticilik, buruşmazlık, katyonik yumuşatıcı, mikro ve makro silikon olmak üzere 6 adet kimyasal apre denemesi uygulanmıştır. Apre reçeteleri düşük-orta-yüksek olmak üzere 3 farklı derişimde hazırlanmıştır (Tablo 6). Apre ardına kurutma işlemleri de 3 farklı sıcaklıkta gerçekleştirilmiştir (Tablo 7). Dolayısıyla 39 (numune) x 6 (apre) x 3 (apre derişimi) x 3 (kurutma sıcaklığı) = Toplam 2106 deney noktasında deneme yapılmıştır. Her deney noktası için 2 tekrar gerçekleştirilmiştir.

Apre denemeleri laboratuvar tipi dikey fularda gerçekleştirilmiştir. Silindir basınçları 1.5 bara ayarlanmıştır. Bu ayarlama yapılırken numune kumaşların pick-up (absorpsiyon) değerlerinin %50'nin üstünde olmasına dikkat edilmiştir. Fuların çalışma hızı 0.5–1 m/dk arasında ayarlanmıştır. Apre flottesinin pH'sı stabiliteyi sağlamak için asetik

Tablo 6. Uygulanan kimyasal apre reçeteleri

Apre Çeşidi	Reçete	Kimyasal Adı	Konsantrasyon		
			D	O	Y
			(g/l)		
Makro-Mikro Silikon (MM)	Makro Silikon	TEKSAMİN NSB	10	20	30
	Mikro Silikon	SETASİL KF	10	20	30
	Islatıcı	RUCOVET NSK	2	2	2
Su İtici (Si)	Teflon	OLEOPHOBOL CMS	40	50	60
	Makro Silikon	TEKSAMİN NSB	12	15	18
	Islatıcı	RUCOVET NSK	2	2	2
Buruşmazlık (BR)	Reçine	FIXAPRET ECO	30	40	50
	Katalizör	MgCl ₂	7.5	10	12.5
	Makro Silikon	TEKSAMİN NSB	10	15	20
	Polietilen	GEMSOL P-41	10	15	20
	Islatıcı	RUCOVET NSK	2	2	2
Katyonik (KA)	Katyonik	SETAFEN SC	10	20	30
	Islatıcı	RUCOVET NSK	2	2	2
Mikro Silikon (Mi)	Mikro Silikon	SETASİL KF	10	20	30
	Islatıcı	RUCOVET NSK	2	2	2
Makro Silikon (MA)	Makro Silikon	TEKSAMİN NSB	10	20	30
	Islatıcı	RUCOVET NSK	2	2	2

D-Düşük, O-Orta, Y-Yüksek

Tablo 7. Numunelerin kurutma sıcaklık (°C) ve süreleri (sn)

Sıcaklık (°C)	P-V Numuneler (sn)						Pamuklu Numuneler (sn)		
	MM-KA-Mİ-MA			Si-BR			MM-KA-Mİ-MA-Si-BR		
	N1	N2	N3	N1	N2	N3	N4	N5	N6
110 – D	140	140	160	155	160	175	100	100	100
130 – O	80	110	120	95	120	130	70	70	70
150 – Y	70	90	100	85	105	115	60	60	60

D-Düşük, O-Orta, Y-Yüksek

asit ile 5–5.5 arasında ayarlanmıştır. Apre flottesini işletmeden alınan yumuşak su ile gerçekleştirilmiştir.

Apre işlemleri ardına numune kumaşların kurutma ve kondense işlemleri laboratuvar tipi germe makinesinde, konveksiyonla ısı iletim prensibine göre gerçekleştirilmiştir. Tüm tipler için kurutma işlemi, sıcaklığın renk üzerindeki etkisini tespit etmek amacıyla 110°C–130°C–150°C olmak üzere üç farklı sıcaklıkta gerçekleştirilmiştir.

2.5. Renk Ölçümü

Boyanmış ve üzerine apre işlemleri uygulanmış kumaşların renk ölçümleri CIELab sistemine göre 10°lik standart gözlemci kullanılarak D65 gün ışığı

altında yapılmış ve L*, a*, b*, C*, h değerleri kaydedilmiştir. Çalışmada Minolta marka, CM 3600 D model bir spektrofotometre kullanılmıştır. Renk ölçümü esnasında cihazın çalıştırılıp, %R değerlerinin kaydedilmesi için RealColor1.3®, renk farkı değerlerinin hesaplanması için CHROMA CMY® yazılımları kullanılmıştır (32).

$$\Delta E^* = [(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2]^{1/2} \quad (\text{Toplam renk farkı}) \quad (4)$$

$$\Delta L^* = (L^*_{\text{numune}} - L^*_{\text{standart}}) \quad (\text{Açıklık-koyuluk renk farkı}) \quad (5)$$

$$\Delta a^* = (a^*_{\text{numune}} - a^*_{\text{standart}}) \quad (\text{Kırmızılık-Yeşillik farkı}) \quad (6)$$

$$\Delta b^* = (b^*_{\text{numune}} - b^*_{\text{standart}}) \quad (\text{Sarılık-mavilik farkı}) \quad (7)$$

$$\Delta C^* = (C^*_{\text{numune}} - C^*_{\text{standart}}) \quad (\text{Doygunluk farkı}) \quad (8)$$

$$\Delta H^* = (h_{\text{numune}} - h_{\text{standart}}) \quad (\text{Açısal renk farkı}) \quad (9)$$

2.6. Orijinal Renk Verileri

Tablo 8'de N1-N2-N3-N4-N5-N6'nın boyanmış 39 numunesinin CIELab değerleri verilmektedir. Apre işlemleri sonrası renk farkı değerleri hesaplanırken, apre öncesi boyanmış numunelerde ölçülen bu CIELab değerleri referans olarak kabul edilmiştir.

Tablo 8. Numune kumaşların apre öncesi CIELab değerleri

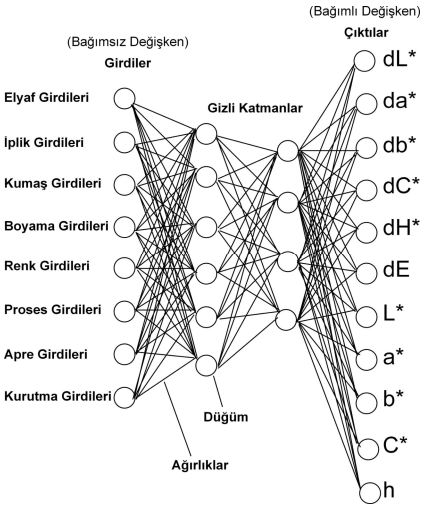
Numune Kumaş	Renk Tonu	Kod	L*	a*	b*	C*	H
N1	Kahverengi-Koyu	N1K.K	18.47	1.71	1.51	2.28	41.57
	Kahverengi-Orta	N1K.O	19.58	3.12	2.8	4.2	41.92
	Kahverengi-Açık	N1K.A	26.21	3.35	3.64	4.95	47.43
	Kahverengi-En Açık	N1K.A1	40.8	5.21	7.92	9.48	56.66
	Bordo-Koyu	N1-B.K	19.78	20.49	6.7	21.56	18.12
	Bordo-Orta	N1-B.O	22.91	28.5	8.44	29.72	16.49
	Bordo-Açık	N1-B.A	31.06	38.12	5.84	38.57	8.7
N2	Kahverengi-Koyu	N2-K.K	17.69	1.56	1.36	2.07	41.03
	Kahverengi-Orta	N2-K.O	18.72	2.98	2.55	3.93	40.57
	Kahverengi-Açık	N2-K.A	25.32	3.27	3.48	4.78	46.8
	Kahverengi-En Açık	N2-K.A1	39.89	5.28	7.92	9.52	56.33
	Bordo-Koyu	N2-B.K	19.33	20.08	6.65	21.15	18.32
	Bordo-Orta	N2-B.O	22.35	28.21	8.63	29.5	17.01
	Bordo-Açık	N2-B.A	30.71	38.27	6.23	38.77	9.25
N3	Kahverengi-Koyu	N3-K.K	17.33	1.22	1.11	1.65	42.33
	Kahverengi-Orta	N3-K.O	17.8	2.65	2.07	3.36	37.89
	Kahverengi-Açık	N3-K.A	23.89	2.96	2.96	4.19	45
	Kahverengi-En Açık	N3-K.A1	38.58	4.82	7.31	8.76	56.6
	Bordo-Koyu	N3-B.K	18.42	18.85	6.15	19.83	18.07
	Bordo-Orta	N3-B.O	21.28	26.81	8.12	28.01	16.84
	Bordo-Açık	N3-B.A	29.39	36.69	5.85	37.15	9.06
N4	Kahverengi-Koyu	N4-K.K	21.63	4.59	5.38	7.07	49.5
	Kahverengi-Orta	N4-K.O	28.26	5.54	7	8.93	51.62
	Kahverengi-Açık	N4-K.A	38.17	5.38	7.86	9.53	55.59
	Bordo-Koyu	N4-B.K	19.42	11.39	4.76	12.34	22.66
	Bordo-Orta	N4-B.O	23.19	17.56	3.87	17.98	12.42
	Bordo-Açık	N4-B.A	30.4	21.89	2.46	22.03	6.43
N5	Kahverengi-Koyu	N5-K.K	22.86	4.73	5.72	7.42	50.45
	Kahverengi-Orta	N5-K.O	30.55	5.59	7.62	9.45	55.73
	Kahverengi-Açık	N5-K.A	40.36	5.47	8.26	9.9	56.51
	Bordo-Koyu	N5-B.K	20.41	11.09	4.43	11.95	21.76
	Bordo-Orta	N5-B.O	25.14	18.37	3.79	18.76	11.66
	Bordo-Açık	N5-B.A	32.57	22.85	2.25	22.96	5.62
N6	Kahverengi-Koyu	N6-K.K	21.21	4.2	5.06	6.58	50.3
	Kahverengi-Orta	N6-K.O	28.45	5.65	6.96	8.96	50.95
	Kahverengi-Açık	N6-K.A	37.64	5.47	7.55	9.32	54.08
	Bordo-Koyu	N6-B.K	19.21	11.76	4.68	12.66	21.71
	Bordo-Orta	N6-B.O	23.69	17.06	3.66	17.45	12.1
	Bordo-Açık	N6-B.A	30.56	21.06	2.33	21.18	6.3

2.7. Yapay Sinir Ağları

Çalışmada YSA kullanarak tahmin yapılmaya çalışılırken, bu tür bir problem için en uygun YSA yapısını oluştur-

ran parametreler de deneysel tasarım yöntemiyle belirlenmeye çalışılmıştır. YSA modellerinin kurulabilmesi için "NeuroSolutions V.5.0" paket programı kullanılmıştır.

Bu bağlamda ilk olarak Şekil 1'deki gibi bir ağ yapısı oluşturulmuştur.




Şekil 1. Çalışılan ağın temel yapısı

Şekil 1'de verilen girdilerin (bağımsız değişkenlerin) seviyeleri;

- Elyaf-iplik-kumaş girdileri Tablo 1 ve 2'de,
- Boyama girdileri Tablo 3 ve 4'de,
- Apre girdileri Tablo 6'da,
- Kurutma girdileri ise Tablo 7'de detaylı olarak verilmiştir.
- Renk girdileri Tablo 8'da verilmiştir.

Farklı yapılarda ağlar kurulurken, bazı ağ parametreleri sabit tutulmuştur. Ağlar kurulurken örneklerin seçilmesi rasgele gerçekleştirilmiştir. Toplam 2106 veriden oluşan girdi seti %75'i (eğitim) - %10'u (çapraz durdurma) - %15'i (test) olacak şekilde sınıflandırılmıştır. Başlangıç değeri rasgele olarak atanmıştır. Çok katmanlı, ileri beslemeli ağ yapısı ve geri yayımlı (BP-backpropagation) öğrenme kuralı ile ağlar oluşturulmuştur. Ağırlıkların değerleri sürekli olarak değiştirilmiştir. Aktivasyon fonksiyonu sigmoid olarak seçilmiştir (Şekil 2). Ağ, çapraz durdurma değerinin MSE'sinin artış gösterdiği devirde eğitimi durdurmuştur. Böylece aşırı öğrenmenin önüne geçilmiştir.



Şekil 2. Sigmoid fonksiyonu

Bu çalışmada, en uygun performans değerleri bulmak için öğrenme kuralı, momentum katsayısı, gizli katman sayısı ve gizli katmandaki düğüm sayısının farklı seviyelerinde ağların performansı ölçülmüş, kurulan deneysel tasarım ile ağ performansı üzerinde etkisi olabilecek parametreler %95 güvenilirlik seviyesinde, tek yönlü ANOVA ile belirlenmeye çalışılmıştır.

2.7.1. Ağların Kurulması ve Eğitimi

Veri setinde bütün kumaş (elyaf, iplik, kumaş), boyama ve apre parametreleri girdi olarak alınmıştır. Veri setinde tüm çalışmayı en açık şekilde temsil eden toplam 38 adet bağımsız değişken (girdi) ve CIELab ve renk farkı değerlerini temsil eden 11 çıktı kullanılmıştır. Bu veri setinde 2106 deney noktası bulunmaktadır. Bu 2106 verinin, 1581 (%75) tanesi ağı eğitmek (train), 210 (%10) tanesi ağı durdurmak (cross validation), kalan 315 (%15) tanesi ise kurulan ağın, tanımayan (unseen data) verilerle test edilmesi için "test verisi" olarak kullanılmıştır. Çıktılar için toplam 111 adet ağ kurulmuştur. Öğrenme oranı ve momentum katsayısı 3, gizli katman sayısı 2, düğüm sayısı ise 10–150 arasında farklı seviyelerde incelenmiştir.

Gizli katmanı tek olan ağlarda öğrenme oranı 0.1, 0.3 ve 0.5, momentum katsayısı 0.7, 0.5, 0.3, düğüm sayısı (proses elemanı) 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 150 olarak 99; çift olanlarda ise öğrenme oranı 0.1, momentum katsayısı 0.7, 0.5, 0.3, düğüm sayısı 10, 50, 100, 150 olarak 12 ağ oluşturulmuştur. Böylece toplam 111 ağ elde edilmiştir. "Full Factorial" analiz yapılmamıştır. Bazı seviyeler gereksiz görülerek tasarımdan çıkarılmıştır.

Ağların performansları değerlendirilirken birinci ölçüt olarak, eğitilen ağ yapısı üzerinde değerlendirilen 315 test verisinin ortalama mutlak sapma değeri (MAE) esas alınmıştır. MAE (Mean Absolute Error) aşağıdaki gibi hesaplanmaktadır.

$$MAE = \frac{\sum_{i=1}^{i=315} |\text{Tahmin CIELabDeğeri} - \text{Gerçek CIELabDeğeri}|}{315} \quad (10)$$

i: Ağı test edilmesinde kullanılan veriler

Tablo 9'da çıktılar için en iyi ağların çalıştığı devir sayıları ve bu devirlerde ulaştıkları minimum MSE değerleri gösterilmiştir.

Tablo 9. Ağların eğitim esnasında gösterdiği performans

Çıktı	Devir Sayısı	Minimum MSE
ΔL^*	2629	0.00032
Δa^*	1952	0.00027
Δb^*	4229	0.00032
ΔC^*	2502	0.00029
ΔH^*	2341	0.00028
ΔE	2269	0.00028
L^*	1787	0.00032
a^*	1055	0.0002
b^*	1787	0.00032
C^*	709	0.00041
h	934	0.00033

3. BULGULAR

3.1. ANOVA Sonuçları

Deneysel tasarıma göre kurulan ağlardan elde edilen tahmini değer-gerçek değer sapmalarına göre ağ performansını etkileyen yapısal parametreler tek yönlü varyans analizi yöntemiyle belirlenmiştir (Tablo 10). Varyans analizi Design-Expert 6.06 paket programı kullanılarak gerçekleştirilmiştir.

İncelenen bağımsız değişkenin, bağımlı değişken üzerinde anlamlı etkisi olabilmesi için "p" değerinin 0.05'den küçük olması, F değerinin ise, F_{kritik} değerinden yüksek olması gerekmektedir. Varyans analizi yapılırken, öğrenme kuralı, momentum katsayısı, gizli katman sayısı ve gizli katmanlardaki düğüm sayısı ağ performansını etkileyebilecek faktörler olarak belirlenirken, sonuçların ortalama mutlak sapması (gerçek değer - ağın tahmin ettiği değer) çıktı olarak kabul edilmiştir.

Tablo 10. İncelenen ağ parametreleri için ANOVA sonucu

Faktör	F Değeri	p değeri	Anlamlılık
Öğrenme Oranı	54.88	<0.0001	Anlamlı
Momentum Katsayısı	24.18	<0.0001	Anlamlı
Gizli Katman Sayısı	0.067	0.4844	Anlamsız
Düğüm Sayısı	30.39	<0.0001	Anlamlı

Tablo 15 incelendiğinde ağ performansını etkilemesi muhtemel dört faktörden, gizli katman sayısı dışında, öğrenme oranının, momentum katsayısının, düğüm sayısının sonuçlar üzerinde anlamlı olarak etkisi olduğu tespit edilmiştir.

3.2. Kurulan Ağların Performansının Test Edilmesi

Ağların performansı, toplam 2106 deney noktasından oluşan veri setinden rasgele olarak ayrılan %15'lik kısım (315 veri) ile test edilmiştir. Tahmin için en iyi ağlar ve topolojileri, gerçek değer ile ağ üzerinden tahmin edilen değerler arasındaki performansın istatistiksel değerlendirmesi Tablo 11 ve 12'de verilmiştir.

Tablo 11 ve 12 incelendiğinde, kurulan ağlar ile gerçekleştirilen tahmin sonrası

korelasyon katsayısı değerlerinin oldukça yüksek, MSE değerlerinin ise küçük olduğu tespit edilmiştir. Korelasyon değerinin 0.8'in üzerinde, MSE değerinin ise 0.1'in altında olması bu tür uygulamalar için yeterli olabilmektedir. Ortalama hata değerlerinin gözün bile çıplak olarak göremeyeceği limitlerde (<1) olduğu belirlenmiş, buna göre de ağın tahmin gücünün oldukça iyi olduğu görülmüştür. Ayrıca ağı test etmek için kullanılan 315 deney noktası için gerçek değer-tahmin değer performansı incelendiğinde, çoğu

noktada 0.5 hata değerinden daha iyi bir performansla kurulan ağın tahmin yaptığı gözlemlenmiştir. Özellikle renk farkı değerleri için YSA'nın çok daha iyi bir performans gösterdiği, ortalama hata değerlerinin 0.1 bile olmadığı, nerdeyse çoğunda 1 değerinin üzerinde sapma olmadığı tespit edilmiştir.

Tablo 13 ve Tablo 14'de ise sırasıyla CIELab değerleri ve renk farkı değerleri için, seçilmiş bazı deney noktaları üzerinden, gerçek ve ağların tahmin ettiği değerler verilmiştir.

Tablo 11. Test sonucu elde edilen istatistik veriler (CIELab değerleri için)

Değerlendirme		Çıktılar				
		L*	a*	b*	C*	h
En İyi Ağ Topolojisi	Öğrenme Katsayısı	0.3	0.3	0.3	0.3	0.3
	Momentum Katsayısı	0.5	0.3	0.5	0.7	0.5
	Gizli Katman Sayısı	1	1	1	1	1
	Proses Elemanı	50	90	50	50	80
MSE		0.082	0.037	0.039	0.05	0.27
Korelasyon - R		0.99	0.99	0.99	0.99	0.99
R ²		0.99	0.99	0.99	0.99	0.99
Ortalama Hata		0.21	0.14	0.1	0.16	0.37
Minimum Hata		0.0004	0.0008	0.0005	0.0001	0.0005
Maksimum Hata		1.27	0.82	2.47	1.6	2.66
Hata Dağılımı (Adet)	0 – 0.1	93	148	193	129	65
	0.1 – 0.2	89	95	90	97	58
	0.2 – 0.5	102	64	27	80	118
	0.5 – 1	24	8	4	6	56
	> 1	2	0	1	3	17

Tablo 12. Test sonucu elde edilen istatistik veriler (Renk farkı değerleri için)

Değerlendirme		Çıktılar					
		ΔL*	Δa*	Δb*	ΔC*	ΔH*	ΔE
En İyi Ağ Topolojisi	Öğrenme Katsayısı	0.1	0.1	0.1	0.1	0.1	0.1
	Momentum Katsayısı	0.5	0.5	0.3	0.3	0.5	0.3
	Gizli Katman Sayısı	1	1	1	1	1	1
	Proses Elemanı	30	100	30	60	60	90
MSE		0.025	0.013	0.009	0.009	0.002	0.01
Korelasyon - R		0.95	0.95	0.93	0.95	0.94	0.94
R ²		0.92	0.92	0.87	0.91	0.89	0.89
Ortalama Hata		0.112	0.076	0.065	0.084	0.037	0.099
Minimum Hata		0.0003	0.0002	0.0003	0.0004	0.0004	0.0003
Maksimum Hata		0.71	0.57	0.77	0.81	0.27	0.71
Hata Dağılımı (Adet)	0 – 0.1	182	236	255	223	297	194
	0.1 – 0.2	81	57	52	62	16	87
	0.2 – 0.5	48	20	5	28	3	32
	0.5 – 1	4	2	3	2	0	2
	> 1	0	0	0	0	0	0

Tablo 13. Bazı seçilmiş deney noktaları için gerçek değer-tahmini değer performansı (CIE Lab Değerleri)

Deney Noktası	L* _{Gerçek}	L* _{Tahmin}	a* _{Gerçek}	a* _{Tahmin}	b* _{Gerçek}	b* _{Tahmin}	C* _{Gerçek}	C* _{Tahmin}	h _{Gerçek}	h _{Tahmin}
1	21.67	21.63	4.98	5.06	6.1	6.15	7.87	7.59	50.78	52.00
2	30.24	30.35	38.69	38.13	6.51	6.64	39.24	39.12	9.55	9.39
3	20.89	20.69	27.16	27.03	8.42	8.58	28.43	28.17	17.23	17.03
4	19.58	19.72	12.49	12.35	4.88	4.86	13.41	13.39	21.35	21.44
5	28.17	27.85	5.95	5.69	7.42	7.10	9.51	9.17	51.27	51.18
6	30.32	30.58	5.41	6.16	7.94	7.79	9.61	9.83	55.72	53.05
7	40.58	40.34	5.64	5.62	8.41	8.59	10.13	10.18	56.15	56.08
8	24.62	24.17	18.95	18.99	4.01	4.13	19.37	19.23	11.95	12.12
9	18.88	19.27	12.61	12.53	4.85	5.10	13.51	13.30	21.04	20.94
10	30.09	30.21	38.48	38.26	6.53	6.57	39.03	39.00	9.63	9.33
11	23.31	23.57	19	19.01	4.51	4.61	19.53	19.35	13.37	13.13
12	18.08	18.05	19.33	19.41	6.24	6.27	20.31	20.33	17.89	17.58
13	21.97	22.10	28.4	28.28	8.77	8.72	29.73	29.54	17.16	17.24
14	19.87	19.27	12.27	12.15	4.65	4.62	13.13	13.09	20.75	20.37
15	38	38.45	5.5	5.55	8.1	8.16	9.79	9.69	55.8	55.55
16	21.93	22.03	28.49	28.60	8.88	8.77	29.84	29.69	17.32	17.34
17	20.97	20.93	27.2	26.92	8.36	8.24	28.46	28.27	17.09	16.80
18	20.04	19.79	12.47	12.47	4.92	4.92	13.41	13.54	21.53	21.49
19	30.32	30.25	21.52	22.02	2.59	2.57	21.68	21.70	6.86	7.09
20	30.59	31.02	38.43	38.23	6.2	6.23	38.93	38.73	9.16	9.29

Tablo 14. Bazı seçilmiş deney noktaları için gerçek değer-tahmini değer performansı (Renk Farklılıkları)

Deney Noktası	ΔL^* _{Gerçek}	ΔL^* _{Tahmin}	Δa^* _{Gerçek}	Δa^* _{Tahmin}	Δb^* _{Gerçek}	Δb^* _{Tahmin}	ΔC^* _{Gerçek}	ΔC^* _{Tahmin}	ΔH^* _{Gerçek}	ΔH^* _{Tahmin}	ΔE _{Gerçek}	ΔE _{Tahmin}
1	-1.19	-1.23	0.25	0.21	0.37	0.43	0.45	0.59	0.04	0.08	1.27	1.29
2	-0.46	-0.46	0.42	0.51	0.28	0.23	0.46	0.45	0.21	0.16	0.69	0.77
3	-0.39	-0.40	0.35	0.46	0.31	0.36	0.42	0.57	0.19	0.29	0.61	0.84
4	-0.83	-0.58	1.4	1.35	0.45	0.43	1.47	1.51	0.09	0.10	1.69	1.53
5	-0.28	-0.40	0.3	0.10	0.46	0.43	0.55	0.34	0.05	0.08	0.62	0.73
6	-0.24	-0.10	-0.18	0.31	0.33	0.15	0.17	0.37	0.33	0.15	0.44	0.50
7	0.22	0.03	0.17	0.21	0.15	0.29	0.22	0.39	0.06	0.03	0.32	0.43
8	-0.52	-0.62	0.58	0.59	0.22	0.18	0.61	0.62	0.09	0.06	0.81	0.85
9	-0.33	-0.40	0.85	0.71	0.17	0.05	0.85	0.60	0.15	0.15	0.92	0.93
10	-0.62	-0.51	0.21	0.24	0.3	0.29	0.25	0.32	0.26	0.24	0.72	0.68
11	0.12	0.15	1.44	1.22	0.65	0.61	1.55	1.42	0.31	0.29	1.59	1.60
12	-0.34	-0.41	0.48	0.44	0.09	0.08	0.48	0.49	0.06	0.01	0.6	0.74
13	-0.38	-0.44	0.2	0.15	0.15	0.19	0.23	0.23	0.08	0.09	0.45	0.47
14	-0.54	-0.59	1.18	1.29	0.22	0.17	1.18	1.24	0.22	0.20	1.31	1.40
15	-0.18	-0.01	0.12	0.01	0.24	0.33	0.27	0.38	0.03	0.08	0.32	0.49
16	-0.43	-0.39	0.28	0.29	0.26	0.24	0.34	0.36	0.16	0.16	0.57	0.58
17	-0.32	-0.32	0.39	0.26	0.25	0.20	0.45	0.37	0.12	0.10	0.56	0.46
18	-0.37	-0.46	1.38	1.07	0.49	0.37	1.46	1.25	0.05	0.06	1.51	1.31
19	-0.25	-0.27	0.46	0.61	0.26	0.25	0.49	0.63	0.21	0.24	0.59	0.85
20	-0.48	-0.33	0.31	0.32	0.36	0.44	0.36	0.36	0.31	0.34	0.67	0.62

4. SONUÇ

Çalışmada ilk olarak, boyanmış tekstil materyalinin CIELab değerleri ölçülüp, boyama + apre sonrasındaki renk farkı değerleri CIELab 1976 formülü ile hesaplanmıştır.

Daha sonra bu amaç için oluşturulan 2106 girdi kullanılarak, YSA tekniği ile apre olmuş numunelerin CIELab de-

ğerlerini ve apre sonrası renk değişimini (çıkıtı) tahmin edebilecek uygun modeller kurulmuştur. Uygun model kurulurken ağın performansını etkileyebilecek YSA parametreleri de ANOVA sonuçlarına göre yorumlanmıştır. Böylece bu tip problemler için yeniden ağ kuracak araştırmacılar için bir öngörü oluşturulmaya çalışılmıştır.

Çalışmadan kurulan ağın performansının, öğrenme oranı, momentum katsayısı ve ağ yapısındaki gizli katmanlarda kullanılan düğüm sayılarından etkilenilebileceği, gizli katman sayısının ise önemli olmayabileceği tespit edilmiştir. Bütün çıktılar için farklı bir ağ en iyi performansı göstermiştir. Bu veriler ışığında, çıktının karakterinin ve gösterdiği dağılımın, kurulacak ağ için

önem arz ettiği söylenebilmektedir. Kurulan ağların korelasyon katsayılarının ve R^2 değerlerinin oldukça iyi olduğu belirlenmiş, tahmin değerlerinin gerçek değerlere göre kabul limitleri içerisinde sapma gösterdiği hesaplanmıştır (Kabul limitleri, ΔE - ΔL^* için 1, Δa - Δb - ΔC^* için 0.6, ΔH^* için 0.3 olarak belirlenmiştir) .

Bu sonuç, kurulan YSA modellerinin, apre uygulamaları sonrası boyanmış

kumaşta meydana gelebilecek renk değişimlerinin tahmininde kullanılabilirliğini göstermektedir. Çıkan tahmin sonuçlarına göre kumaşta meydana gelebilecek renk değişimi boyama yapılmadan öngörülebilecek ve boyama reçeteleri bu değişime göre modifiye edilerek, son mamul üründeki renk (değeri) hedeflenebilecektir. Mamulde apreye bağlı olarak renk değişimi ve dolayısıyla bu sonucun düzeltmeye gerek olup olmadığına ΔE

değerine bakılarak karar verilirken, reçetede yapılacak modifikasyonlar ΔL^* , Δa , Δb ve ΔH^* 'e göre belirlenebilecektir. Böylece mamul kalite kontrol dairelerinde renk farkından dolayı ortaya çıkan fireler ve düzeltme proses uygulamaları minimize edilebilecek, ilk seferde doğru üretim amacına katkıda bulunulabilecektir.

KAYNAKLAR / REFERENCES

1. Elmas, Ç., 2003, *Yapay Sinir Ağları*, Seçkin Yayıncılık, İstanbul.
2. Rumelhart De, 1986, Learning Internal Representation By Error Propagation. In: Parallel Distributed Processing, Cambridge, Ma: Mit Press, Vol.1, 318-362.
3. Krose, B., Smaget, P., V., D., 1996, *An Introduction To Neural Networks*, The University of Amsterdam, Amsterdam.
4. Duda, R., O., Hart, P., E., Stork, D., G., 2000, *Pattern Classification*, Wiley-Second Edition.
5. Cuff, J.A., Barton, G. J., 1999, Evaluation And Improvement Of Multiple Sequence Methods For Protein Secondary Structure Prediction. *Proteins: Structure, Function, And Genetics*, 34, 508-519.
6. Cheng, K., P., S., Lam, H., L., I., 2003, "Evaluating And Comparing The Physical Properties Of Spliced Yarns By Regression And Neural Network Techniques", *Textile Research Journal*, Yıl:73, No:2, 161-164.
7. Kanfeng, W., Kai, L., Xiubao, H., 2004, "Prediction Of Worsted Yarn By Using Neural Network", *Proceedings of the Textile Institute 83rd World Conference*, 1362-1367.
8. Majumdar, A., Majumdar, P., K., Sarkar, B., 2004, "Prediction Of Single Yarn Tenacity Of Ring And Rotor Spun Yarns From Hvi Results Using Artificial Neural Networks", *Indian Journal of Fibre & Textile Research*, Vol 29, 157-162.
9. Beltran, R. Wang, L., Wang, X., 2004, "Predicting Worsted Spinning Performance with An Artificial Neural Network Model", *Textile Research Journal*, Vol.74, 757-763.
10. Majumdar, A., Majumdar, P., K., Sarkar, B., 2005, "Application Of An Adaptive Neuro-Fuzzy System for The Prediction of Cotton Yarn Strength From HVI Fibre Properties", *Journal of Textile Institute*, Vol.96, No.1, 55-60.
11. Lewandowski, S., Stanczyk, T., 2005, "Identification And Classification Of Spliced Wool Combed Yarn Joints By Artificial Neural Networks Part I. Developing And Artificial Neural Network Model", *The Fibres&Textiles In Eastern Europe*, Vol.13, No.1(49), 39-43.
12. Lewandowski, S., Stanczyk, T., 2005, "Identification And Classification Of Spliced Wool Combed Yarn Joints By Artificial Neural Networks Part II. Interpretation of Identification And Classification Results of the Unknotted Spliced Yarns Joints", *The Fibres&Textiles In Eastern Europe*, Vol.13, No.2(50), 16-19.
13. Ramesh, M., C., Rajamanickam, R., Jayaraman, S., 1995, "Prediction of Yarn Tensile Properties By Using Artificial Neural Networks", *Journal of the Textile Institute*, Vol.86, No.3, 459-469.
14. Babay, A., Cheikhrouhou, M., Vermeulen, B., 2004, "Selecting The Optimal Neural Network Architecture For Predicting Cotton Yarn Hairness", *The Journal of Textile Institute*, Vol. 96, No.3, 185-192.
15. Lin, J., J., 2007, "Prediction of Yarn Shrinkage Using Neural Nets", *Textile Research Journal*, Vol. 77, No.5, 336-342.
16. Fan, K., C., Wang, Y., K., Chang, B., L., Wang, T., P., 1998, "Fabric Classification Based On Recognition Using Neural Network and Dimensionality Reduction", *Textile Research Journal*, Yıl:68, No:3, 179-185.
17. Shiao, Y., Tsai, S., Lin, C-S., 2000, "Classifying Web Defects With A Back-Propagation Neural Network By Color Image Processing", *Textile Research Journal*, Yıl:70, No:7, 633-640.
18. Tilacco A., Borzone, P., Carosio, S., Durante, A., 2002, "Detecting Fabric Defects With A Neural Network Using Two Kinds of Optical Patterns", *Textile Research Journal*, Yıl:72 No:6, 545-550.
19. Chen, P., B., Liang, T., C., Yau, H., F., 1998, "Classifying Textile Faults With A Back-Propagation Neural Network Using Power Spectra", *Textile Research Journal*, Yıl:68, No:2, 121-126.
20. Ertuğrul, S., Uçar, N., 2000, "Predicting Bursting Strenght of Cotton Plain Knitted Fabrics Using Intelligent Techniques", *Textile Research Journal*, Yıl:70, No:10, 845-851.
21. Gong, R., H., Chen, Y., 1999, "Predicting The Performance of Fabrics in Garment Manufacturing With Artificial Neural Networks", *Textile Research Journal*, Yıl:69, No:7, 477-482.
22. Tokarska, M., 2004, "Neural Model of The Permeability Features of Woven Fabrics", *Textile Research Journal*, Yıl:74, 1045-1048.
23. Bhattacharjee, D., Kothari, V., K., "A Neural Network System For Prediction of Thermal Resistance of Textile Fabrics", *Textile Research Journal*, Yıl:77, No.1, 4-12.
24. Allan, G., Yang, R., Fotheringham, A., 2001, "Neural Modelling Of Polypropylene Fibre Processing: Predicting The Structure and Properties And Identifying The Control Parameters For Specified Fibres", *Journal of Materials Science*, Yıl:36, 3113-3118.
25. Uçar, N., Ertuğrul, S., 2007, "Prediction of Fuzz Fibres on Fabric Surface By Using Neural Network and Regression Analysis", *Fibres and Textiles in Eastern Europe*, Vol.15, No.2 (61), 58-61.
26. Spehl, J., Wölker, M., Kettler, W., 1994, "Application of the Backpropagation Nets for Color Recipe Prediction as a Nonlinear Approximation Problem", *IEEE*, 3336-3341.
27. Mizutani, E., Jang, J., R., Nishio, K., 2005, "Coactive Neuro-Fuzzy Modeling for Color Recipe Prediction", www.ieeexplore.ieee.org.
28. Senthilkumar, M., Selvakumar, N., 2006, "Achieving Expected Depth of Shade in Reactive Dye Application Using Artificial Neural Network Technique", *Dyes and Pigments*, Vol.68, 89-94.
29. Westland, S., Lovine, L., Bishop, J., M., 2002, "Kubelka-Munk or Neural Networks for Computer Colorant Formulation", *9th Congress of the International Color Association, Proceedings of SPI*, Vol.4421, 745-748.
30. Westland, S., 1998, "Artificial Neural Networks and Colour Recipe Prediction", *Proceedings of the International conference and Exhibition, Colour Science*.
31. Balcı, O., Oğulata, S., N., Şahin, C., "Predicting of CIELab Data and Wash Fastness of Nylon 6,6 Using Artificial Neural Network and Linear Regression Model", *Fiber&Polymers*, (In press).
32. Duran, K., 2001, *Tekstilde Renk Ölçümü ve Reçete Çıkartma*, E.Ü.Tekstil Ve Konfeksiyon Araştırma-Uygulama Merkezi Yayını, Yayın No:17, İzmir.

Bu araştırma, Bilim Kurulumuz tarafından incelendikten sonra, oylama ile saptanan iki hakemin görüşüne sunulmuştur. Her iki hakem yaptıkları incelemeler sonucunda araştırmanın bilimselliği ve sunumu olarak "**Hakem Onaylı Araştırma**" vasfıyla yayımlanabileceğine karar vermişlerdir.