

DOKUZ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BOYAHANELERDE LABORATUVAR İLE
İŞLETME ARASINDAKİ RENK
DEĞİŞİMLERİNDEN KAYNAKLANAN
HATALARIN AZALTILMASI**

Aslı SARIDERELİ

Nisan, 2010

İZMİR

**BOYAHANELERDE LABORATUVAR İLE
İŞLETME ARASINDAKİ RENK
DEĞİŞİMLERİNDEN KAYNAKLANAN
HATALARIN AZALTILMASI**

Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi

Tekstil Mühendisliği Bölümü, Tekstil Mühendisliği Anabilim Dalı

Aslı SARIDERELİ

Nisan, 2010

İZMİR

YÜKSEK LİSANS TEZİ SINAV SONUÇ FORMU

ASLI SARIDERELİ tarafından DOÇ. DR. MERİH SARIİŞİK yönetiminde hazırlanan “BOYAHANELERDE LABORATUVAR İLE İŞLETME ARASINDAKİ RENK DEĞİŞİMLERİNDEN KAYNAKLANAN HATALARIN AZALTILMASI” başlıklı tez tarafımızdan okunmuş, kapsamı ve niteliği açısından bir Yüksek Lisans tezi olarak kabul edilmiştir.

Doç. Dr. Merih SARIİŞİK

Danışman

Jüri Üyesi

Jüri Üyesi

Prof.Dr. Mustafa SABUNCU

Müdür

Fen Bilimleri Enstitüsü

TEŞEKKÜR

00065.STZ.2007-1 nolu SAN-TEZ projesi kapsamında, bu tez çalışmasına desteklerinden dolayı Sanayi Bakanlığı'na ve Ekoten Tekstil A.Ş.'ye teşekkür ederim. Projenin yürütücüsü ve tez danışmanım Doç. Dr. Merih SARIİŞİK'a teşekkür ederim. Projenin yapay sinir ağları ve bulanık mantık çalışmalarında desteklerinden dolayı Yrd. Doç. Dr. Yavuz ŞENOL'a ve Volkan SAĞIRLIBAŞ'a teşekkür ederim. Ekoten Tekstil A.Ş. üretim müdürü Birkan YURDAKUL'a ve Ekoten Tekstil A.Ş. çalışanlarına teşekkür ederim.

Aslı SARIDERELİ

BOYAHANELERDE LABORATUVAR İLE İŞLETME ARASINDAKİ RENK DEĞİŞİMLERİNDEN KAYNAKLANAN HATALARIN AZALTILMASI

ÖZ

Son yıllarda gerek kalite anlayışı ve gerekse tüketici beklentilerine paralel olarak boyama işleminde ekolojik, ekonomik ve zamanında teslim kriterleri ön plana çıkmıştır. Özellikle reaktif boyamada bir kerede doğru boyama yapmak ve tekrarlanabilirliği sağlamak çok önemli olup, artan rekabet koşulları her firmayı hızlı hareket etmeye zorlamaktadır. Gerek iç piyasada gerekse özellikle ihracata yönelik üretimde müşteri isteği doğrultusunda laboratuvarda istenilen renk tutturulup, numune boyama yapılmakta ve müşteri onayı alındıktan sonra da esas üretime geçilmektedir. Bu noktada, yani numune boyama sonuçlarının esas üretime aktarılmasında renk farklılığı sorunu ile karşılaşmaktadır.

Klasik boyama reçeteleri Kubelka-Munk teorisine (Beer yasası) göre çalışan bilgisayarlı renk ölçüm makinalarında tahminlenmekte ve bu reçetelerle işletme ortamında boyama gerçekleştiğinde renkte sapmalar olmaktadır. Kubelka-Munk teorisine dayanan sistemlerde konsantrasyon-absorbsiyon arasındaki ilişkide doğrusallığı bozan pek çok faktör göz ardı edilmekte, bu ise reçete hesabında hata payını arttırmaktadır. Doğrusallığı bozan pek çok faktörün de hesaba katıldığı yapay sinir ağları gibi yeni sistemlerde hata payı azalmaktadır.

Bu çalışmada, yapay sinir ağları ve bulanık mantık yöntemleri kullanılarak renk reçetesi tahmini yapılmış ve ortaya çıkan sonuçlar karşılaştırılmıştır. Ayrıca laboratuvar koşullarında çeşitli parametrelerdeki sapmaların sonuçlara etkisini gözlemlemek amacıyla, laboratuvar ortamında denemeler yapılmıştır.

Anahtar sözcükler: Renk reçetesi tahmini, K-M modeli, yapay sinir ağları, bulanık mantık

REDUCING THE DEFAULTS CAUSED BY THE COLOR DIFFERENCES BETWEEN THE LABORATORY AND THE MILL IN THE DYEHOUSES

ABSTRACT

Recently, economic, ecologic and on-time delivery criteria for the dyeing industry have come forward in parallel with the latest quality definition and customer demands. Particularly with the reactive dyeing, getting the right color at the first shot and the repeatability of the color are very important as increasing competition in the market is forcing every company to move fast. After the customer approves the color checking the specimens dyed with the color prepared in the laboratory according to the customers demand, mass dyeing is achieved for domestic and especially for foreign sales. But it is possible to see color differences between the mass production and the specimens dyed.

Classical dye recipes are generated by computerized color measuring equipments which are working according to Kubelka-Munk theory (Beer Law) and differences in color are observed when dyeing is achieved according to these recipes in the mill. In systems based on Kubelka-Munk theory, a lot of factors that break linearity between concentration and absorption are not taken into consideration and this causes error risk to increase in recipe prediction. In recent systems like artificial neural networks in which a lot of factors that break linearity are taken into consideration, error risk becomes to decrease.

In this thesis color recipe prediction was done by using artificial neural networks and fuzzy logic and the results were compared. Besides, experiments were done in laboratory to investigate the results of diffraction at various factors in laboratory conditions.

Keywords: Colour recipe prediction, K-M model, artificial neural networks, fuzzy logic

İÇİNDEKİLER

Sayfa

YÜKSEK LİSANS TEZİ SINAV SONUÇ FORMU	ii
TEŞEKKÜR.....	iii
ÖZ	iv
ABSTRACT.....	v

BÖLÜM BİR – GİRİŞ 1

1.1 Reaktif Boyarmaddeler.....	1
1.1.1 Reaktif Boyarmaddelerle Boyama Yöntemleri	5
1.1.1.1 Çektirme Yöntemine Göre Boyamalar	5
1.1.1.2 Emdirme Yöntemine Göre Boyamalar	7
1.2 Renk Ölçümü.....	8
1.2.1 Spektral Yöntem	8
1.2.2 Renk Ölçüm Prensibi.....	9
1.3 Reçete Çıkarma	11
1.3.1 Reçete Hesaplamanın Esasları.....	14
1.3.2 Renk Reçetesi Hesabında Kullanılan Yeni Yöntemler.....	16
1.4 Yapay Sinir Ağları.....	16
1.4.1 Yapay Sinir Ağlarında Bilginin Depolanması ve Geri Alınması	18
1.4.2 Yapay Sinir Ağlarının Genel Kullanım Alanları.....	18
1.4.3 Yapay Sinir Ağlarının Tarihçesi	19
1.4.4 Biyolojik Bir Beyin Sinir Hücresinin Yapısı.....	22
1.4.5 Bir Yapay Sinirin Ana Öğeleri	24
1.4.6 Yapay Sinir Ağlarının Oluşturulması	30
1.4.6.1 Çok Katmanlı Sinir Ağı Yapısı (Multi Layer Perceptron-MLP)	34
1.4.6.2 Radyal Tabanlı Fonksiyon (Radial Basis Function-RBF)	35
1.4.7 Yapay Sinir Ağlarının Tekstilde Kullanımı.....	35
1.4.7.1 Renk Reçetesi Tahminlenmesinde Sinir Ağlarının Kullanımı.....	43

1.5 Bulanık Mantık.....	45
1.5.1 Bulanık Sistemlerinin Gelişimi.....	48
1.5.2 Bulanık Küme Kuramı ve Bulanık Mantık.....	50
1.5.3 Bulanık Mantık Denetleyicinin Üstünlük ve Sakıncaları	52
1.5.3.1 Üstünlükler.....	53
1.5.3.2 Sakıncalar.....	53
1.6 Genetik Algoritma ve Tarihçesi	54
1.6.1 Genetik Algoritmaların Uygulama Alanları	55
BÖLÜM İKİ – MATERYAL VE YÖNTEM.....	57
2.1 Materyal.....	57
2.1.1 Kullanılan Boyarmadde, Kimyasal Maddeler ve Cihaz	57
2.1.1.1 Cihaz	57
2.1.1.2 Boyarmadde	57
2.1.1.3 Kimyasal Maddeler.....	58
2.1.2 Kumaş	58
2.2 Yöntem	58
2.2.1 Laboratuvar Parametre Denemeleri	61
2.2.1.1 Boyama Reçetesi.....	62
2.2.1.2 Boyama Grafiği.....	63
2.2.1.3 Yıkama İşlemi.....	64
2.2.1.4 Renk Ölçümü	64
2.2.2 Yapay Sinir Ağları ile Reçete Tahmini	65
2.2.2.1 Uygulama (1)	65
2.2.2.2 Uygulama (2)	71
BÖLÜM ÜÇ – ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	74
3.1 Laboratuvar Parametre Denemeleri Sonuçları	74
3.1.1 Tuz Miktarı	74
3.1.2 Alkali Miktarı	76


3.1.3 Boyama Süresi	78
3.1.4 Boyama Sıcaklığı	80
3.1.5 Flotte Oranı	82
3.2 Laboratuvar Parametrelerinin İstatistiksel Olarak Değerlendirilmesi	83
3.2.1 Tuz Miktarı	83
3.2.2 Alkali Miktarı	86
3.2.3 Boyama Süresi	89
3.2.4 Boyama Sıcaklığı	92
3.2.5 Flotte Oranı	95
3.3 Yapay Sinir Ağları ile Reçete Tahmini Sonuçları	98
3.3.1 Uygulama (1) Sonuçları	98
3.3.1.1 RBF Uygulamaları	98
3.3.1.2 MLP Uygulamaları	117
3.3.2 Uygulama (2) Sonuçları	157
3.3.2.1 MLP Uygulamaları	157
3.3.2.2 İşletme Boyamaları için Uygulama Sonuçları	162
3.4 Bulanık Mantık ile Reçete Tahmini Sonuçları	166
3.4.1 Uygulama (1) Sonuçları	166
3.4.1.1 ANFIS Uygulamaları	166
BÖLÜM DÖRT - SONUÇLAR	183
KAYNAKLAR	18

BÖLÜM BİR

GİRİŞ

1.1 Reaktif Boyarmaddeler

Günümüzde selülozik esaslı mamullerin boyanmasında en çok tercih edilen yöntemlerden biri olan reaktif boyarmadde ile boyama, selüloz makromoleküllerindeki –OH grupları ile boyarmaddedeki reaktif gruplar arasında uygun koşullar altında kovalent bağların oluşturulması esasına dayanır. Reaktif boyarmaddelerin yapısında bu yüzden selülozdaki hidroksil grupları ile reaksiyona girebilen reaktif bir kısım, rengi veren kromofor bir kısım, bu iki kısım arasında bulunan bir köprü ve reaksiyonun veya boyamanın sulu ortamda gerçekleşmesinden dolayı da suda çözünürlük sağlayan gruplar bulunmalıdır.




Şekil 1.1 Reaktif boyarmaddelerin şematize yapısı (Rys ve Zollinger, 1975)

Selüloz boyamacılığında bu kadar önemli olan reaktif boyarmaddeleri diğer boyarmadde sınıflarından ayıran en belirgin husus, bu boyarmaddelerde lif makromolekülleri ile tepkimeye giren grupların bulunmasıdır. Bu grupların reaktiflik derecesine bağlı olarak, reaktif boyarmaddelerin boyama koşulları (sıcaklık, zaman ve alkali) arasında önemli farklılıklar göstermektedir. Boyarmadde molekülündeki reaktif gruplar, selüloz lifindeki hidroksil gruplarla kovalent bağ oluşturmaktadır. Reaktif boyarmaddeleri life bağlanma mekanizmasına göre iki gruba ayırmak mümkündür.


- Heteroçiklik halka esaslı reaktif boyarmaddeler
- Vinilsülfon esaslı reaktif boyarmaddeler

Reaktif boyarmaddelerin yaklaşık 2/3'ü heteroçiklik halka, 1/3'ü de korunmuş vinilsülfon esaslı reaktif grup içermektedir. Heteroçiklik halka esaslı reaktif grupların, selüloz makromoleküllerindeki –OH grupları ile reaksiyonu bir **nükleofil substitüsyon (yer değiştirme)** reaksiyonu olarak tanımlanabilir.



Şekil 1.2 Heteroçiklik halka esaslı reaktif boyarmaddenin pamuk lifine yer değiştirme reaksiyonu ile kovalent bağlanması (D = Boyanın kromofor grubu, cell = selüloz) (Ratee, 1995)

Vinilsülfon esaslı reaktif boyarmaddelerin selüloz makromoleküllerindeki –OH grupları ile reaksiyonu ise iki adımda meydana gelmektedir. Önce alkalinin etkisi ile vinilsülfon grubu oluşmakta, ikinci adımda da **nükleofil adisyon (katılma)** reaksiyonu ile selüloz makromoleküllerindeki –OH gruplarından biri bu vinil grubuna bağlanmaktadır (Yurdakul, 2006).



Şekil 1.3 Vinilsülfon esaslı reaktif boyarmaddenin pamuk lifine katılma reaksiyonu ile kovalent bağlanması (Rys ve Zollinger, 1975)

Boyama şartları ve yöntemleri, boyarmaddenin substantifliğine ve reaktif grubun reaktifliğine göre değişmektedir. Bundan dolayı kullanılan sıcaklık, boya banyosuna ilave edilen tuz ve alkalinin cinsi, miktarı ve banyoya ilave şekli çeşitli reaktif boyarmaddeler arasında farklılıklar gösterir.

Reaktif boyarmaddeler, reaktif grupların reaktifliklerine göre iki grupta toplanacak şekilde özellik gösterirler:

a) Yüksek reaktifliğe sahip, soğukta boyayan boyarmaddeler;

Soğukta boyayan reaktif boyarmaddeler için sıcaklık 20-40°C arasındadır. Reaktiflik yüksek olduğu için sıcaklığı yükseltmeden ve alkali ilavesini arttırmadan elyaf ile çok kolay reaksiyona girerler. Bunların avantajları;

- Daha hızlı boyama yapmak,
- Daha az kimyasal madde tüketimi,
- Daha az enerji tüketimi,
- Yüksek boyarmadde verimi,
- Tekrarlanabilme olanağının daha iyi olması,
- Aynı zamanda düşük substantiviteyi yüzünden yıkamalarının çok kolay olmasıdır. Yüksek sıcaklıkta durulama yeterlidir.

b) Düşük reaktifliğe sahip, sıcakta boyayan boyarmaddeler;

Boyama sıcaklıkları 60-80°C arasındadır. Reaksiyon kabiliyetleri zayıf olduğu için sıcaklığı yükseltmek ve alkali ilavesini arttırmakla aktivite sağlanır. Sıcak boyamada sıcaklığın yüksekliği nedeniyle çok düzgün boyamalar elde edilir ve boyarmadde nüfuziyeti mükemmeldir. Bunların en büyük avantajları;

- Hidroliz tehlikesinin az olması
- Daha iyi nüfuz etmeleridir (M. Yakartepe ve Z. Yakartepe, 1995).

Reaktif boyarmaddelerle çektirme yöntemine göre boyamalar, ister soğukta ister sıcakta boyayan boyarmadde tipleri ile yapılsın, prensip olarak boyama işlemi 3

adımdan oluşmaktadır. Boyarmaddenin lifler tarafından alınması (*migrasyon adımı*), boyarmaddenin lifle reaksiyona girmesi (*fiksaj adımı*), hidrolize uğramış, life fikse olmamış boyarmadde kısmının mamülden uzaklaştırılması (*yıkama adımı*) (Yurdakul, 2006).

Reaktif boyarmaddelerle boyama sırasında, boyarmaddenin reaktif grubu, yalnız selüloz makromoleküllerinin hidroksil gruplarıyla değil, aynı zamanda suyun hidroksil grupları ile de tepkimeye girerek hidrolize uğrarlar. Hidrolize uğrayan boyarmadde lifle reaksiyona girme aktivitesini kaybederek boyama veriminin düşmesine neden olur. Ayrıca liflere mekanik olarak bağlanarak boyamanın yaş haslıklarının düşmesine neden olur. Hidrolizin tamamen önlenmesi mümkün değildir. Ancak, azaltılması için önlemler vardır.


Bunlardan birincisi; ortamda az su bulunan emdirme metodunu uygulamaktır. Diğeri; boyarmaddenin selüloz lifine afinitesini arttırmaktır. Ancak life afiniteyi arttıran yöntemler hidrolizi de arttırmaktadır. Üçüncü ve en etkili yol, baz ilavesini mümkün derece geciktirmektir. Piyasada bulunan ve çift reaktif grup içeren bifonksiyonel ya da daha fazla reaktif grup içeren polifonksiyonel boyarmaddelerde, boyarmaddenin life bağlanma şansı bir kat fazladır.

Bazik ortamda lif ile reaksiyon hızı, hidroliz hızından çok fazla ise de boyarmaddenin %15-20 kadar kaybı söz konusudur. Isı hidrolizi artırır. Bu nedenle, bazın flotteye en son ve soğukta ilavesi hidroliz hızını azaltır. Nötr ortamda reaksiyon yavaştır ve hidroliz ihmal edilebilecek kadar azdır. Baz ilave edilir edilmez, reaksiyon ve hidroliz hızlanır. Vinil grubu suyun hidroksil grubu ile de reaksiyona girerek, elyafla birleşme özelliğini kaybeder.

Reaktif boyarmadde, ortamda nişasta varsa, nişastanın –OH grupları ile de birleşir. Bu nedenle kumaş üzerinde nişasta haşılı artıkları varsa iyice temizlenmelidir (M. Yakartepe ve Z. Yakartepe, 1995).

1.1.1 Reaktif Boyarmaddelerle Boyama Yöntemleri

Bu boyarmaddelerle hem çektirme hem de emdirme yöntemine göre çalışılabilmekte olup, Şekil 1.4'te de görüldüğü gibi uygulama tekniği açısından boyarmaddelerin yarından çoğunun çektirme yöntemine göre applike edildiği söylenebilir (Yurdakul, 2006).



Şekil 1.4 Reaktif boyarmaddelerin aplikasyon oranları (Yurdakul, 2006)

1.1.1.1 Çektirme Yöntemine Göre Boyamalar

Reaktif boyarmaddelerle çektirme yöntemine göre ister sıcakta ister soğukta çalışılsın boyanacak olan materyale, boyama koyuluğuna, boyarmadde cinsine, boyama cihazına bağlı olarak çok çeşitli boyama yöntemleri tavsiye edilmektedir. Reaktif boyamada hangi yöntemle çalışılırsa çalışılsın, düzgün ve tekrarlanabilir boyama eldesi için;

- Boya flottesindeki boyarmadde konsantrasyonu
- Boya flottesindeki tuz konsantrasyonu
- Boya flottesinin pH değeri
- Boya flottesinin sıcaklığı

parametrelerine özellikle dikkat edilmeli ve bunlar boyama prosesi boyunca kontrol altında tutulmalıdır. Bu parametrelerin dışında, boyanacak kumaşın;

- alkali atıkları
- klor ve peroksit atıkları
- nişasta ve benzeri haşıl atıkları


içermemesine dikkat edilmelidir. Ayrıca yüksek boyarmadde verimi için boyanacak olan kumaşın mümkünse kostikleme veya merserize işlemi görmesi gerektiği unutulmamalıdır.

Reaktif boyarmaddelerde boyama işlemi ya sabit sıcaklıkta (izoterm) boyama ya da boyamaya düşük sıcaklıkta başlayarak sıcaklığın artırılması şeklinde yapılmaktadır. Boyama flottesine alkalinin konuluş şekline göre dört ana yöntem bulunmaktadır.

- **İki basamaklı yöntem:** Daha çok soğukta boyayan boyarmaddelerde kullanılan bu yöntemde, flotteye önce tuz ve boyarmadde konulmakta, boyarmadde alımı bir dengeye ulaşıldıktan sonra da alkali ilavesi ile boyamaya devam edilmektedir. Boyarmaddenin lifler tarafından alınmasını kontrol edebilmek için boyanacak mala, rengin açık-koyu oluşuna, firmadan firmaya göre tuzun ve boyarmaddenin porsiyon halinde ilavesi, daha az tuzla çalışma, boyarmadde aldırma adımını uzatma gibi önlemler alınmaktadır. Boyanması zor olan bazı mamüllerde, turkuaz ve yeşil gibi renklerde iki basamaklı yöntemin biraz değiştirilmiş şekli olan migrasyon yöntemi uygulanmaktadır. Boyamanın birinci adımında boyama sıcaklığının üzerindeki sıcaklıkta (15-30 dak.) boyarmaddenin yer değiştirmesi sağlanmaktadır. Daha sonra boyama sıcaklığına düşürülerek standart yöntemdekine benzer şekilde boyamanın ikinci adımına devam edilmektedir.
- **Baştan biraz alkali koyma yöntemi:** Bu yöntem özellikle substantifliği düşük boyarmaddeler kullanıldığında tercih edilmektedir. Flotteye boyarmadde ve tuz yanında alkalinin bir kısmı verilerek boyamaya

başlanmakta, asıl boyama sıcaklığına çıkıldıktan sonra da alkalinin geri kalan kısmı ilave edilerek boyama yapılmaktadır. Bu boyama yönteminde boyamanın düzgünlüğü hem sıcaklık hem de alkali kontrolü ile sağlanmaktadır.

- **Her şeyi baştan koyma yöntemi:** Bu yöntem özellikle sıcakta boyayan boyarmaddelerle otomatik kontrol programı olan makinelerde uygulanmaktadır. Floteye boyarmadde ve tuzun yanı sıra alkali de baştan itibaren konulmaktadır. Bu boyama yönteminde boyamanın kontrolü sıcaklık ile sağlanmaktadır.
- **Programlı alkali ilavesi yöntemi:** Bu yöntem esas itibariyle izoterm bir boyama olup, alkali ve istenirse tuz ve boyarmadde ilaveleri otomatik dozaj donatımı yardımı ile yapılır. Böylece pH- değerlerindeki sıçramalardan kaynaklanabilecek düzgünsüz boyamalar önlenabilmektedir (Yurdakul, 2006).



Şekil 1.5 Programlı alkali ilavesi metodu (Yurdakul, 2006)

1.1.1.2 Emdirme Yöntemine Göre Boyamalar

Emdirme yönteminde kullanılan reaktif boyarmaddelerin payı %26 civarındadır. Bunun yaklaşık %15'ini pad-batch, geriye kalan %11'lik kısmını ise diğer yöntemler oluşturmaktadır. Reaktif boyarmaddelerle çok çeşitli emdirme yöntemleri uygulanabilirse de bunların arasında en yaygın olanları;

- Pad-batch (soğuk bekletme)
- Pad-steam
- Termofiksaj
- Econtrol yöntemleridir (Yurdakul, 2006).

1.2 Renk Ölçümü

Bir tekstil mamulünün alıcıda satın alma isteği uyandırmasında en önemli etkenlerin başında renk ve desen gelmektedir. Renkler modağa bağılı olarak sık sık değışmekte, boyahane işletmelerine müşteri tarafından getirilen bir rengin veya daha önce boyanan bir rengin aynısının tutturulması için yoğun çabalar sarfedilmektedir.

Tekstil terbiyesinde renk ve reçete eldesi ile ilgili her türlü problem bugün artık “bilgisayar destekli entegre renk ölçüm sistemleri” ile çözülmektedir. Renk ölçüm aletlerinin tekstil endüstrisinde kullanımı ile birlikte boyacılar çalışmalarını bilimsel bir şekilde yapabilme ve objektif deęerlendirme imkanı doğmuştur. Renk ölçümünde kullanılan başlıca üç yöntem vardır. Bunlar;

1. Karşılaştırma yöntemi,
2. Üç filtre ölçme yöntemi,
3. Spektral yöntem.

Bütün bu yöntemler gözdeki görme mekanizması ve karşılaştırma sistemi esasına dayanmaktadır (Duran, 2001).

1.2.1 Spektral Yöntem

Bu yöntemde spektrofotometreler ile fiziksel olarak renk ölçümü yapılır. Renk ölçümünün temel yöntemi olarak kabul edilir.



Şekil 1.6 Spektrofotometre

Spektral yöntemde ışık kaynağından gönderilen ışınlar kullanılır. Monokromotorda ayarlanan ışık, dalga boyuna göre gönderilir. Ölçümlerde dalga boyu aralıkları ölçme aletinin tipine bağlıdır. Fakat bu mesafeler genellikle transmisyon ölçümlerinde 0,5-2 nm, refleksiye ölçümlerinde ise 10 nm'ye kadar olabilir.


Monokromotordan kırılarak gelen ışınlar ölçülerek renkli numune üzerine (veya refleksiye ölçümünde numuneyi kendisi ile karşılaştıracak beyaz standart “ideal beyaz” üzerine) düşer. Gelen ışınlar ölçümü yapılacak numuneden kısmen geçirilir veya yansıtılır. Yansıtılan veya geçirilen ışınlar daha sonra fotoelektriksel alıcı üzerine düşerler. Burada elektrik enerjisinden yararlanılarak doğrudan doğruya remisyon değeri galvanometreden okunur (Duran, 2001).

1.2.2 Renk ölçüm Prensipleri

Rengin ölçüm prensipleri için çok eski dönemlere dayanan çalışmalar bulunmaktadır. Bu çalışmalar 1600'li yıllardan başlamış, 1970'lerin sonuna kadar sürmüştür. Bu tarihsel süreç içinde Oswald, Munsell, Manfred Richter, CIE ve CIELab renk sistemi önemli noktalar olmuştur.

CIE sistemi Uluslararası Aydınlatma Komisyonu (**Comission Internationale de L'eclerage**) tarafından geliştirilmiş olup, standart renk kısımlarından x ve y kromatisite koordinatları kullanılarak elde edilir. Ancak CIE düzlemsel renk sistemi rengin açıklığı-koyuluğu ve nüansı hakkında fikir vermede yetersiz kalmaktadır.

Bunun üzerine 1970’li yıllarda tekstil endüstrisinde geniş bir kullanım alanı bulan CIELab sistemi geliştirilmiştir.



Şekil 1.7 CIELab renk sistemi (Duran, 2001)

CIELab sisteminde renklerin sayısal olarak ifadesinde kullanılan X, Y, Z değerlerinden hesaplanan L^* , a^* , b^* değerleri kullanılmaktadır. Şekil 1.9 da görülen bu sistemde aynı düzlem üzerinde bulunan ve birbirini merkezde kesen a^* ve b^* eksenleri bulunur. Üçüncü eksen ise a^* - b^* eksenlerinin oluşturduğu eksene dik gelen L^* eksen olup, rengin açıklığını gösterir. CIELab renk sisteminde birbirleri ile eşit tonda bulunan renkler aynı düzlem üzerinde bulunurlar. Düzlem üzerinde renksiz noktadan rengin bulunduğu noktaya çizilen doğrunun a^* eksenine ile yaptığı h açısı, renk tonu için bir ölçektir. Bu açı kırmızıdan sarıya doğru giderek artar. Örneğin; $h = 0^\circ$ kırmızı bir renk tonuna, $h = 90^\circ$ sarı bir renk tonuna, $h = 270^\circ$ mavi bir renk tonuna karşılık gelmektedir.

Rengin bulunduğu noktanın, renksiz noktaya olan uzaklığı, rengin C ile ifade edilen doygunluk değerini gösterir. Bu değer rengin belli bir açıklıktaki parlaklığı ve duruluğu için de bir ölçektir (Duran, 2001).

$$L^* = 116 (Y/Y_n)^{1/3} - 16 \text{ (Açıklık-koyuluk)} \quad (1)$$

$$a^* = 500[(X/X_n)^{1/3} - (Y/Y_n)^{1/3}] \text{ (Kırmızı-Yeşillik)} \quad (2)$$

$$b^* = 200[(Y/Y_n)^{1/3} - (Z/Z_n)^{1/3}] \text{ (Sarı-mavilik)} \quad (3)$$

$$C^* = (a^2 + b^2)^{1/2} \text{ (Parlaklık)} \quad (4)$$

$$h = \arctan(b/a) \text{ (Açı cinsinden renk değeri)} \quad (5)$$

Bu formüller Y/Y_n değerinin 0.008856'dan büyük olması durumunda geçerlidir.

Y/Y_n değerlerinin 0.008856'ya eşit veya daha az olması durumunda aşağıdaki formül geçerlidir:

$$L = 903.3(Y/Y_n) \quad Y/Y_n \leq 0.008856 \quad (6)$$

a^* ve b^* değerlerinin hesaplanması X/X_n , Y/Y_n ve Z/Z_n 'nin 0.008856'ya eşit veya daha az olması durumunda aşağıdaki formüller yardımıyla yapılır.

$$a^* = 500[(f(X/X_n)^{1/3} - f(Y/Y_n)^{1/3})] \quad (7)$$

$$b^* = 200[f(Y/Y_n)^{1/3} - f(Z/Z_n)^{1/3}] \quad (8)$$

Bu denklemlerde X , Y , Z rengin tristimulus değerleridir. X_n , Y_n ve Z_n ise ölçümde kullanılan ışık kaynağının tristimulus değerleridir. Tristimulus her bir dalga boyunda bu unsurlara ait büyüklüklerin çarpımlarının toplamı olarak tanımlanır. %R ise yansıma değeridir (Öner, 2006).

1.3 Reçete Çıkarma (Boyama Reçetelerinin Eldesi)

Koloristlerden boyarmaddelerin çeşitli konsantrasyonlardaki kombine edilebilirlikleri hakkındaki tecrübelerine dayanarak, verilen bir numuneye göre yapılacak boyama için reçete hazırlanması istenebilir. Böyle bir durum karşısında koloristin reçeteye koyacağı boyarmaddeler ile yapılacak boyamadan elde edilecek renk hakkında bir ön görüşe sahip olması gerekir.

Koloristik tecrübeler yerine reçete hesaplanmasından yararlanarak bir reçete elde etmek isteniyorsa, boyarmadde konsantrasyonu ve elde edilecek renk arasındaki ilişkilerin iyi bilinmesi ve kantitatif olarak formülle ifade edilmesi gerekir.


Yapılan bir boyamanın rengi, standart renk değerleri yardımıyla kantitatif olarak yazılacaksa, boyarmadde konsantrasyonu ile X , Y , Z arasındaki ilişkiler araştırılır. Reçete hesaplanmasında boyanmak üzere verilmiş bir numuneden, ölçülen $X;Y;Z$ değerleri ile boyama sonunda aynı X , Y , Z değerini verecek bir reçetenin çıkarılması temel görevdir.

Bir boyama reçetesinin çıkarılması oldukça zor ve vakit alıcı bir işlemdir. Deneyimli bir koloristin bile reçeteyi oturtabilmesi için çok sayıda ön deneme yapması gerekmektedir. Renk ölçümü yoluyla boyama reçeteleri çıkarılması çalışmaları oldukça eskiye dayanmaktadır. Ancak uygulamaya dönük reçete çıkarma çalışmaları 1960'lı yıllarda başlamış ve başarıya ulaşmıştır.

Bilgisayarlı reçete eldesinde koloristlerin deneyimlerini kullanarak çabuk, emin ve optimal bir reçete eldesi hedeflenir. Verilen bir rengin aynısının koloristik tecrübelerle dayanılarak tutturulması, kombinasyonda kullanılan boyarmaddeler hakkında geniş tecrübelerle dayanılarak mümkün olabilmektedir. O tecrübe, boyamadaki boyarmadde konsantrasyonu ve öngörülen renk hakkındaki histir. His ve tecrübelerle yakalanan o ilişkileri, hesap yoluyla da ortaya koymak mümkündür. Reçete hesaplamanın esasını, istenen rengin refleksiyon değerlerinden hareketle bilgisayarda yapılan bir dizi hesaplamalar oluşturmaktadır. Aynı şekilde reçete düzeltme hesaplarını da yapmak mümkündür.

Reçete hesaplaması tekstil endüstrisinde yaklaşık 1970 yılından beri giderek daha yaygın bir kullanım alanı bulmuş ve bu arada renk ölçümünün en fazla işe yaradığı yer olmuştur. Renk ölçümü bugün sadece renk ölçüm aleti üreticilerini değil, bilgisayar üreticilerini ve programcılarını da ilgilendiren bir konu haline gelmiştir.

Bugün böyle bir reçete hesaplama sistemi renk ölçme aleti (spektrofotometre), bir bilgisayar ile renk ölçümü ve reçete hesaplama için software'den oluşmaktadır.



Şekil 1.8 Spektrofotometrenin çalışma prensibi

Bilgisayarın, koloristlerde olduğu gibi herhangi bir koloristik tecrübeye sahip olmaması nedeniyle, boyarmaddelerin boyamalardaki davranışları hakkındaki her türlü bilginin verilmesi gerekmektedir. Bu nedenle bir defaya mahsus olmak üzere her boyarmaddeden belli konsantrasyonlarda boyamalar yapılır ve refleksiyonları ölçülür. Bu ölçüm değerleri bilgisayarın hafızasına yüklenerek reçete hesaplamalarında sürekli kullanılır.

Bir rengin reçetesinin subjektif olarak tahminlemesinde kolorist öncelikle örneği inceler. Bu adım reçete hesaplamasında rengin refleksiyon değerlerinin ölçümünün karşılığıdır.

Subjektif değerlendirmede olduğu gibi reçete hesaplamada da boyarmadde seçimi için deneyimli bir kolorist gereklidir. Boyarmaddeler boyama yöntemi, materyal, kullanım yeri ve istenen haslık değerleri gibi özellikler göz önünde bulundurularak eldeki mevcutlar arasından özenle seçilmelidir.

Tecrübeye dayanarak subjektif olarak yapılan reçete tahminlerinde normalde bir reçete çıkarılırken, bilgisayarda reçete hesaplamalarında seçilen boyarmaddelerle mümkün olan bütün alternatifler hesaplanarak birden fazla reçete hesabına gidilir.

Hesaplanan reçetelerde boyarmadde konsantrasyonlarının yanında ayrıca birim maliyet fiyatı, metameri indeksi gibi hususlar da verilmektedir. Kolorist bunlar arasından kendisine en uygun optimal reçeteyi seçme durumundadır. Seçilen reçete önce laboratuarda denenir. Laboratuar deneylerinin sonucuna göre, bazı durumlarda reçetede düzeltmeler gerekebilir. Düzeltilmiş bir reçetenin eldesi ilk laboratuarda boyanan rengin ölçümü ve düzeltme hesaplaması yoluyla olabilir.

Tecrübeye dayanarak yapılan reçete tahminlemelerinde örnek ile elde edilen renk gün ışığında aynı olmasına karşın, diğer suni ışıklar altında belirgin şekilde sapmalara rastlanmaktadır. Bu durumda reçetede kullanılan boyarmadde kombinasyonunu değiştirmek gerekmektedir. Bu hususta hesap yoluyla elde edilen reçetelerde metameri indeksi hangi kombinasyonların daha uygun olduğu hakkında fikir vermektedir.

Modern yöntemle hesaplama yoluyla reçete eldesinde koloristin görevi daha da önemle devam etmektedir. Reçete eldesi için daha az vakit harcamasına karşın, her yönüyle optimal reçetenin saptanması ve uygulanması bakımından birçok yeni teknik görevler de yüklenmektedir (Duran, 2001).

1.3.1 Reçete Hesaplamanın Esasları

Reçete hesaplama boyarmadde kombinasyonları ve bunların konsantrasyonları o şekilde belirlenmelidir ki; elde edilen refleksiyon değerleri, mümkün olduğunca örnek renginki ile aynı olmalıdır.

Refleksiyon (R) ve konsantrasyon (C) arasındaki ilişki bilinmelidir.

$$C = f (R) \qquad R = f (C)$$

Kubelka Munk Formülü :

$K/S = (1 - R)^2 / 2 R$ bir dalga boyunda bir yandan refleksiyon (R) ve diğer yandan da örneğin absorpsiyonu (K) ve yansımaları (S) arasındaki ilişkileri

vermektedir. Renkli tekstil mamullerinde (K) genellikle boyarmadde ve (S) ise sadece tekstil materyali tarafından belirlenir.

Beer Kanunu :

$A * C = K/S$ şeklinde ifade edilmektedir ki, burada absorbsiyonun (K), yansımaya (S) oranı, konsantrasyonu verir. Ancak burada (C) bir oransal faktör olan (A) faktörü (Absorbsiyon katsayısı) ile çarpılmalıdır. Bu absorbsiyon katsayısı (A) her boyarmadde için ayrıdır.

Kubelka Munk formülü yardımıyla belli bir dalga boyu için hesaplanan K/S değeri, bu dalga boyunda o renkli tekstilin absorbsiyonu için bir ölçektir. Renkli bir tekstil materyalinin absorbsiyonu; tekstil materyalinin absorbsiyonu (Kt) ve boyarmaddenin absorbsiyonu (Kf)'nin toplamına eşittir. Yani :

$$K/S = (K_t + K_f) / S = (1 - R^2) / 2R \quad (9)$$

Sadece boyarmaddenin sahip olduğu absorbsiyon (Kf) Beer kanuna göre konsantrasyon ile orantılı olarak, tek boyarmadde ile yapılmış bir boyama için :

$$K/S = K_t / S + A.C \quad (10)$$

şeklinde hesaplanabilir. Bu formüldeki A; boyarmaddenin K/ S faktörünün içinde kabul edilen bir absorbsiyon katsayısıdır.

Birden fazla boyarmadde (örneğin: üç) için bu bağıntı geliştirilerek :

$$K/S = K_t / S + A_1. C_1 + A_2. C_2 + A_3. C_3 \quad (11)$$

halini alır (Duran, 2001).

Kubelka Munk teorisine dayanan sistemlerde konsantrasyon-absorbsiyon arasındaki ilişkide doğrusallığı bozan ;

- Boyarmadde molekül büyüklüğü
- Boyarmadde ve tuz konsantrasyonlarındaki artış
- Dalga boyuna bağlı absorpsiyondaki negatif veya pozitif değişim
- Boya çözeltisinin sıcaklığındaki değişimler
- pH'daki varyasyonlar
- Boya-boya etkileşimleri
- Boya-tuz etkileşimleri

gibi pek çok faktör göz ardı edilmekte, bu ise reçete hesabında hata payını arttırmaktadır.

Doğrusallığı bozan pek çok faktörün de hesaba katıldığı yeni sistemlerde reçete hesabında hata payı azalmaktadır.

1.3.2 Renk Reçetesi Hesabında Kullanılan Yeni Yöntemler

- Yapay Sinir Ağları (Artificial Neural Networks)
- Bulanık Mantık (Fuzzy Logic)
- Genetik Algoritma (Genetic Algorithm)

1.4 Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yoluyla yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya mümkün değildir. O nedenle, yapay sinir ağlarının, programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş adaptif bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olduğu söylenebilmektedir (Öztemel, 2003).

Yapay sinir ağıları bir programcının geleneksel yeteneklerini gerektirmeyen, kendi kendine öğrenme düzenekleridir. Bu ağılar öğrenmenin yanı sıra, ezberleme ve bilgiler arasında ilişkiler oluşturma yeteneğine de sahiptir.

Yapay sinir ağıları bilgi işleme sistemlerinin yeni neslini temsil ederler. Genel olarak yapay sinir ağıları model seçimi ve sınıflandırılması, işlev tahmin, en uygun değeri bulma ve veri sınıflandırılması gibi işlerde başarılıdır. Geleneksel bilgisayarlar ise özellikle model seçme işinde verimsizdir ve sadece algoritmaya dayalı hesaplama işlemleri ile kesin aritmetik işlemlerde hızlıdırlar (Elmas, 2003).

Yapay sinir ağıları ile modelleme ve tahmin uzun yıllardır gelişimini sürdüren bir tekniktir. Literatür, 1990'lu yıllardan itibaren bu tekniğin tekstilde de kullanılabilir olduğunu göstermektedir. Yapılan incelemede, özellikle bu tekniğin tekstilde iplik endüstrisi üzerine uygulanarak başladığı, daha sonra tekstilin hammaddeden, hazır giyime kadar her alanına uygulandığı tespit edilmiştir. Tekstilde problemler genellikle lineer olmayan davranış göstermektedir. Yapay sinir ağıları her girdi ile çıktı arasında gizli katmanlar vasıtasıyla tek tek ilişki kurduğundan lineer olmayan problemlerin çözümünde daha verimli olduğu belirlenmiştir. Sistemin çok katmanlı oluşu, ortaya çıkan hatanın geriye doğru düzeltilerek işleyebilme avantajı sağlamaktadır (Balcı, 2008).

Bir çok yapay sinir ağı tipi bulunmakla birlikte bazılarının kullanımı diğerlerinden daha yaygındır. En çok kullanılan yapay sinir ağı, Geri Yayımlı yapay sinir ağı olarak bilinendir. Bu tip yapay sinir ağı tahmin ve sınıflandırma işlemlerinde çok iyi sonuçlar vermektedir. Bir başkası Kohonen Özörgütlemeli Harita'dır. Bu tip sinir ağıları, karışık bilgi kümeleri arasında ilişki bulma konusunda başarılı sonuçlar vermektedir.

1.4.1 Yapay Sinir Ağlarında Bilginin Depolanması ve Geri Alınması

Yapay sinir ağlarına herhangi bir örnek giriş verisinin tanınabilmesi ve bunun daha sonra kullanılabilmesi için verinin ağda nasıl temsil edildiğini, nerede saklandığını ve nasıl geri alındığının bilinmesi gerekmektedir.

Klasik bilgisayarlarda bilgi 1 ve 0 serileri ile temsil edilirken, sinir ağlarında matematiksel işlev ile temsil edilir. İşlem elemanları arasındaki bağlantının ağırlıkları bu işlevin değişkenleri olarak görev yaparlar. Burada ağırlıklar saklanan bilginin ne olduğuna karar verir, fakat kendilerinin bir anlamı yoktur.

Sinir ağlarındaki bilgi, ağ içindeki bağlantılarda ve birçok ağırlıklar yoluyla dağıtılmaktadır. Klasik bilgisayar bilgiyi belleğinde belirli bir yerde saklar, sinir ağları ise bilgiyi tüm ağ boyunca dağıtır. Bu durum dağıtılmış bellek olarak bilinir.

Klasik bilgisayarda bilgi, belirli bellek bölgesine ulaşılarak alınır. Sinir ağlarında ise bilgi muhtemelen gürültülü ya da tamamlanmamış giriş örneği olarak ağa sunulur. Ağ, giriş ile tüm ihtimalleri birleştirerek en iyi ve en uygun örneği çıkış olarak seçer. Bu çıkış örneği, ağ tarafından giriş örneği hakkında eldeki bilgi olarak temsil edilir. Bu durum ise birleştirilmiş bellek olarak bilinir (Elmas, 2003).

1.4.2 Yapay Sinir Ağlarının Genel Kullanım Alanları

Günümüzde yapay sinir ağları üzerine araştırmalar iki alan üzerine yoğunlaşmıştır. Bunlardan birincisi ileri beslemeli çok katmanlı ağlar ikincisi ise Hopfield ağlarıdır. Yapay sinir ağları bilgi sınıflama ve bilgi yorumlamanın da içinde bulunduğu çok değişik problemlerin çözümünde kullanılmaktadır. Yapay sinir ağlarının kullanıldığı alanlar özet olarak şu şekilde sıralanabilir;

- Denetim
- Sistem modelleme
- Ses tanıma

- El yazısı tanıma
- Parmak izi tanıma
- Elektrik işareti tanıma
- Meteorolojik yorumlama
- Otomatik araç denetimi
- Fizyolojik işaretleri (Kalp fonksiyonları gibi) izleme, tanıma ve yorumlama

Yukarıda verilen başlıklara ilave olarak, yapay sinir ağları, her türlü bilgiyi işlemek ya da analiz etmek amacıyla kullanılırlar. İş hayatı, finans, endüstri, eğitim ve karışık problemlerli bilim alanlarında, bulanık veya var olan basit yöntemlerle çözülemeyen problemlerin çözümünde, doğrusal olmayan sistemlerde başarıyla uygulanmaktadırlar.

Yapay sinir ağlarının başlıca uygulama alanları sınıflandırma, tahmin ve modelleme olarak ele alınabilir.

Sınıflandırma: Müşteri/Pazar profilleri, tıbbi teşhis, imza tetkikleri, borçlanma/risk değerlendirmeleri, ses tanıma, şekil tanıma, spektrum tanımlaması, mal değeri, hücre tiplerinin sınıflandırılması, mikroplar, modeller, örnekler.

Tahmin: İleriki satışlar, üretim ihtiyacı, pazar performansı, ekonomik deliller, enerji ihtiyacı, tıbbi sonuçlar, kimyasal reaksiyon ürünleri, hava tahminleri, at yarışları, çevresel risk, jüri panelleri.

Modelleme: İşlem kontrolü, sistem kontrolü, kimyasal yapılar, dinamik sistemler, işaret karşılaştırma, plastik kalıpcılık, kaynak kontrolü, robot kontrolü ve diğer birçok uygulamalar (Elmas, 2003).

1.4.3 Yapay Sinir Ağlarının Tarihçesi

İnsan beyni hakkındaki çalışmalar binlerce yıl öncesine dayanır. Modern elektroniğin gelişmesi ile birlikte, bu düşünce işlemini kullanmaya çalışmak doğal

bir hale gelmiştir. İlk yapay sinir ağı modeli 1943 yılında, bir sinir hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağını modellemişlerdir.

1948 yılında Wiener “Cybernetics” isimli kitabında, sinirlerin çalışması ve davranış özelliklerine değindi. 1949 da ise Hebb “Organization of Behavior” isimli kitabında, öğrenme ile ilgili temel teoriyi ele aldı.

Hebb kitabında öğrenebilen ve uyum sağlayabilen sinir ağları modeli için temel oluşturacak Hebb Kuralı’nı ortaya koymuştur. Hebb Kuralı sinir ağının bağlantı sayısı değiştirilebilirse, öğrenebileceğini öngörmekteydi. 1950’li yıllardan sonra birçok araştırmacı Hebb kuralı’ndan esinlenerek yapay sinir ağlarının hesaplama gücünü artırıcı yönde çalışmalar yapmıştır. IBM araştırma laboratuvarlarında yapılan bir sinir ağı benzetimi (simulasyon) çalışmaları başarısızlıkla sonuçlanmasına karşın sonraki girişimlerde başarı sağlanmıştır. 1957 yılında Frank Rosentblatt’ın Perceptron’u gerçekleştirmesinden sonra yapay sinir ağı alanındaki gelişmeler hızlanmıştır. Perceptron, beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar neticesinde ortaya çıkan tek katmanlı eğitilebilen ve tek çıkışa sahip olan yapay sinir ağıdır.

Bu çalışmalara yardımcı olmak için, John Von Neuman vakum tüplerini ve rölelerini kullanarak basit sinir işlevlerini taklit etmeyi önermiştir. Frank Rosentblatt ise anlama ve kavrama hakkında çalışmalara başlamıştır. Rosentblatt, bir sineğin göz işlemleriyle ilgilenmiştir. Bir sineğe kaçmasını söyleyen işlemlerin çoğu sineğin beyni yerine gözünün içinde yapılması, *kavrama düğümü* diye adlandırılan ağ yapısının kurulmasını sağlamıştır. Tek katmanlı bir kavrama düğümünde, giriş değerleri ağırlıklı toplamı hesaplanarak, bir eşik değeri çıkarılmakta ve iki olası değerden biri sonuç olarak alınmaktadır. Kavrama düğümü bugün kullanımda olan en eski sinir ağıdır.

1959 yılında, Bernard Widrow ve Marcian Hoff ADALINE ve MADALINE diye adlandırdıkları ağ modellerini geliştirdiler. MADALINE, telefon hatlarında oluşan yankıları yok eden bir uyarlanabilir süzgeç olarak kullanılmış, gerçek dünya sorunlarına uygulanmış olan ilk sinir ağıdır. Bu dönemde en dikkat çekici çalışma Widrow'un 1963 yılında yaptığı 'ters sarkaç' denetleyicisidir.

1969 yılında Minsky ve Papert Perceptron'un yetersizliğini görmüşler ve XOR problemini çözemediğini ispatlamışlardır. Bunun için iki katmanlı ileri beslemeli ağların kullanılabileceğini ileri sürmüşler ve tek katmanlı ağlardaki birçok sınırlamayı ortadan kaldırdığını göstermişlerdir. Fakat gizli katmanların ağırlıklarının nasıl değiştirileceği konusunda bir yöntem önerememişlerdir. Bu soruna Rumelhart ve arkadaşları geri yayılım yöntemi ile bir çözüm getirmişlerdir.

Bu erken başarılar, insanların sinir ağlarının potansiyelini abartması sonucunu doğurdu. Abartılı beklentilerin gerçekleştirilememesi bu beklentileri hayal kırıklığına dönüştürdü. Aynı zamanda, bazı bilim kurgu yazarları 'düşünen makinelerin' insanları nasıl etkileyeceğini ele almalarına yol açtı. Asimov robotlar hakkındaki kitaplarında, düşünen makinelerin, özellikle insanoğlunun ahlaki değerlerine olan etkilerini konu aldı. Diğer bazı yazarlar ise çok daha korkunç bilgisayarların yaratılacağı hakkında abartılı kitaplar yazdılar. Bu yersiz ve abartılı iddialar, yapay sinir ağları araştırmalarının kesilmesine yol açtı. Bu ilginç gelişme 1981 yılında sona erdi.

Tüm bunlara rağmen, Anderson, Wilshaw, Kanerva ve Kohonen gibi az sayıdaki sinir ağının savunucuları sessiz araştırmalarına devam ettiler. Son yıllarda yapılan çalışmalarla, yapay sinir ağları her alanda yaygın olarak kullanılmaya ve başarılı sonuçlar alınmaya başlanmıştır.

Seksenli yıllar sinirsel hesaplama çalışmaları için bir atılım dönemi olmuştur. Hopfield 1982 yılında ağların önemli sınıflarının matematik temellerini üretmiştir.

1984 de Kohonen sinirlerin düzenli sıralanışına eşleme özelliği için danışmansız öğrenme ağlarını geliştirmiştir.

1985 yılına kadar, Amerikan Ulusal Fizik Akademisi (National Academy of Sciences of the USA), yapay sinir ağları ile ilgili gelişmeleri izlemiş ve desteklemiştir.

1986 da Rumelhart ve McClland karmaşık ve çok katmanlı ağlar için geriye yayılmalı öğrenme algoritması ortaya koymuştur.

1987 yılında Elektrik Elektronik Mühendisliği Enstitüsü (Institute of Electrical Electronic Engineering (IEEE)) tarafından sinir ağlarını konu alan ilk uluslararası konferans 1800'ü aşkın katılımcıyla gerçekleştirilmiştir (Elmas, 2003).


1.4.4 Biyolojik Bir Beyin Sinir Hücresinin Yapısı

Yapay sinir ağlarının daha iyi anlaşılması için örnek teşkil eden doğal sinir ağı olan biyolojik sinir ağlarının yapısının ve çalışma ilkelerinin iyi bilinmesi gerekmektedir.

İnsan beyninin en temel parçası, hatırlama, düşünme, her harekette daha önceki deneyimlere başvurma yeteneğini sağlayan kendine özgü sinir hücreleridir. İnsan beyinde yaklaşık 10^{11} sinir hücresi vardır. Her bir biyolojik sinir hücresinin yaklaşık 10.000 kadar komşu bağlantısı vardır ve bu sinirlerden uyarı alır. İnsan beyninin çalışma frekansı 100 Hz'dir, ağırlığı yetişkin bir insanda yaklaşık 1,3 kg dır.

Sinir hücreleri kabaca çok kutuplu, iki kutuplu, tek kutuplu, anaksonik olmak üzere öbeklendirilebilir. Bizim örnek aldığımız sinir çok kutuplu tiptedir. Yani çok sayıda dendriti ve tek bir aksonu vardır. Bu sinirlerin hücre gövdeleri omurilik (medulla spinalis)'in ön boynuzunda bulunur ve miyelin tabaka ile çevrelenmiştir. Miyelin tabaka stoplazma ile hücreler arası sıvı arasındaki kapasiteyi düşürerek,

işaretlerin yayılma hızını arttırmaya yarayan yalıtım maddesidir. Miyelinli sinirlerle iletim, miyelinsizlere göre oldukça hızlıdır.



Şekil 1.9 Nöronun yapısı (<http://www2.cedarcrest.edu/academic/bio/>)

Ayrıca miyelin tabaka ile kaplı akson üzerinde her birkaç mm’de bir yer alan ve işaretleri periyodik olarak yeniden üretmeye yarayan ranvier adı verilen boğumlar vardır. Bununla birlikte, tüm doğal sinirlerin 4 temel bileşeni vardır. Bunlar, dendritler, soma, akson ve sinapstır. Temel olarak biyolojik sinir diğer kaynaklardan girişleri alır, soma girişleri genelde doğrusal olmayan bir şekilde işler. Akson işlenmiş girişleri çıkışa aktarır. Sinaps diğer sinirlere çıkışı gönderir.

Bir sinirden diğer bir sinapsa işaretlerin taşınması karmaşık bir kimyasal süreçtir. Burada özel verici substancesler birleşmeden sonra giden son işaretle serbest kalır. Alınan işaret hücrenin içindeki elektrik potansiyelinin daha altındaysa etki ortaya çıkar. Eğer potansiyel bir eşik değerine ulaşırsa akson içine bir işaret gönderir. Buna hücrenin uyarılması denir.

Sinirin işlevi sinaps boyunca dentrite ulaşan uyarıları alarak, bunlardan aksiyon potansiyeli oluşturmak veya oluşturmamaktır. Aksiyon potansiyeli genel olarak 0,1 mV genliğinde 1 milisaniyelik elektriksel nabızı alır ve akson boyunca 120 m/s hızda hareket eder.

Hareket potansiyeli, akson ucundaki sinapsa ulaşınca, elektriksel uyarıdan kimyasal uyarıya dönüşerek, sinaps aralığından postsinaptik sinirine geçer.

Postsinaptik sinirin zarında kimyasal uyarı elektriksel uyarıya dönüştürülür ve dentritler boyunca somaya ulaştırılır. Bir sinaps ya uyarıcı ya da inhibe edici olabilir. Uyarıcı sinapslar uyarıcı sinir aksiyon potansiyelini artırır, inhibe edici sinapslar ise uyarıcı sinir aksiyon potansiyelini azaltır.

Bir sinir hücresinin yüzey zarının iç ve dış tarafında potansiyel fark vardır. Bitişik sinirin sinapsından gönderilen nörotransmitter kimyasal işaretler sinirin zar potansiyelini ayarlar. Sinapslar, darbe-kodlu elektriksel sinirsel işaretleri nörotransmitter işaretlere dönüştürür.


Her akson üzerinden geçen işaretleri değerlendirebilecek yetenekte olduğu varsayılmaktadır. Bu değerlendirme bir işaretin belli bir sinir için ne kadar önemli olduğunu göstermektedir.

Etkinlik " $x(t)$ " ve işaretin " $S(x(t))$ " nörofizyolojik yorumu potansiyel farkın elektriksel darbelerini ve zamansal toplamalarını içermektedir. Etkinlikler küçük zar darbelerini içerir. İşaretler ise geniş aksonal darbeleri veya etkinlik potansiyelleri içerir.

Matematiksel olarak gerçek değerli etkinlik ($x(t)$) sinirin yüzey zarında t zamanındaki potansiyel farkını (gerilim) temsil eder. Etkinlik pozitif veya negatif olabildiği gibi teorik olarak sonsuz da olabilir (Elmas, 2003).

1.4.5 Bir Yapay Sinirin Ana Öğeleri

Yapay sinir ağları, birbirine bağlı çok sayıda işlem elemanlarından oluşmuş, genellikle paralel işleyen yapılar olarak adlandırılabilir. Yapay sinir ağlarındaki işlem elemanları basit sinirler olarak adlandırılır. Bir yapay sinir ağı, birbirleriyle bağlantılı, çok sayıda düğümlerinden oluşur.



Şekil 1.10 Yapay sinir ağı (bir katman) (<http://tr.wikipedia.org/>)


Yapay sinir ağları, insan beyni gibi, öğrenme, hatırlama ve genelleme yeteneğine sahiptirler.

İnsan beyninde öğrenme 3 şekilde olur;

- Yeni aksonlar üreterek
- Aksonların uyarılmasıyla
- Mevcut aksonların güçlerini değiştirerek

Her aksonun, üzerinden geçen işaretleri değerlendirebilecek yetenekte olduğu savunulmaktadır. Aksonun bu özelliği, bir işaretin belli bir sinir için ne kadar önemli olduğunu göstermektedir.

Yapay sinir ağlarının temel birimi işlem elemanı ya da düğüm olarak adlandırılan yapay bir sinirdir. Bir yapay sinir, biyolojik sinirlere göre daha basit olmasına karşın, biyolojik sinirlerin 4 temel işlevini taklit ederler.



Şekil 1.11 Temel bir yapay sinir hücresi (Elmas, 2003)

Girişler x_i sembolüyle gösterilmiştir. Bu girişlerin her biri ağırlık w ile çarpılır. Basitçe, bu ürünler eşik değeri θ_j ile toplanır ve sonucu oluşturmak için etkinlik işlevi ile işlem yapılır ve y_i çıkışı alınır.

Tüm yapay sinir ağları bu temel yapıdan türetilmiştir. Bu yapıdaki farklılıklar yapay sinir ağlarının farklı sınıflandırılmalarını sağlar. Bir yapay sinirin öğrenme yeteneği, seçilen öğrenme algoritması içerisinde ağırlıkların uygun bir şekilde ayarlanmasına bağlıdır.

a) Girişler

Girişler $(x_1, x_2, \dots, x_n)$ çevreden aldığı bilgiyi sinire getirir. Girişler, kendinden önceki sinirlerden veya dış dünyadan sinir ağına gelebilir. Bir sinir genellikle gelişmiş bir çok girdileri alır.

b) Ağırlıklar

Ağırlıklar $(w_1, w_2, \dots, w_i)$, yapay sinir tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılarıdır. Her bir giriş kendine ait bir ağırlığa sahiptir. Bir ağırlığın değerinin büyük olması, o girişin yapay sinire güçlü bağlanması ya da

önemli olması, küçük olması zayıf bağlanması ya da önemli olmaması anlamına gelmektedir.

c) Toplama İşlevi

Toplama işlevi v_i , sinirde her bir ağırlığın ait olduğu girişlerle çarpımının toplamalarını eşik θ_j değeri ile toplayarak etkinlik işlevine gönderir. Bazı durumlarda toplama işlevi bu kadar basit bir işlem yerine, enaz (min), ençok (max), çoğunluk veya birkaç normalleştirme algoritması gibi çok daha karmaşık olabilir.

d) Etkinlik İşlevi

Toplama işlevinin sonucu, etkinlik işlevinden f (*etkinlik*) geçirilip çıkışa iletilir. Bir etkinlik işlevinin kullanım amacı, zaman söz konusu olduğunda toplama işlevinin çıkışının değişmesine izin vermektir.

e) Ölçekleme ve Sınırlama

Düğümelerde, etkinlik işlevinin sonuçları ölçek veya sınır işlemlerinden geçebilir. Bu ölçeklendirme basitçe bir örnek etmeni ile etkinlik değerinin çarpımının sonucudur. Sınırlandırma ise, ölçeklenmiş sonuçların en az ve en çok sınırlarını aşmamasını sağlamaktır.

f) Çıkış İşlevi

Çıkış $y_i = f(s)$, etkinlik işlevi sonucunun dış dünyaya veya diğer sinirlere gönderildiği yerdir. Bir sinirin tek bir çıkışı vardır. Sinirin bu çıkışı, kendinden sonra gelen herhangi bir sayıdaki diğer sinirlere giriş olabilir.

Her bir düğümde bir çıkış işaretine izin verilir. Bu işaret diğer yüzlerce sinir hücresinin girişi olabilir. Bu durum biyolojik sinirde olduğu gibidir. Biyolojik sinirde de birçok giriş varken sadece bir çıkış etkinliği vardır. Düğüm çıkışı etkinlik

işlevinin sonucuna eşdeğerdir. Fakat bazı ağ yapıları, komşu düğümler arasında yarışma oluşturmak için etkinlik sonuçlarını düzenleyebilir. Böylece yarışmacı girişler hangi düğümün öğrenme ya da uyma işlemine katılacağına karar verilmesinde yardımcı olur.

Tablo 1.1 Biyolojik sinir ağı ile yapay sinir ağının karşılaştırılması

Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir	Düğüm (Sinir, işlem elemanı)
Sinaps	Sinirler arası bağlantı ağırlıkları
Dendrit	Toplama işlevi
Hücre Gövdesi	Etkinlik işlevi
Akson	Sinir çıkışı

g) Öğrenme

Öğrenme kuralı Hebbian öğrenme kuralı denilen basit bir modele dayanır. Hebbian öğrenme kuralı temel olarak “Eğer iki düğüm aynı zamanda etkin ise aralarındaki bağ gücü artar.” kuramına dayanmaktadır. Öğrenmenin amacı her bir düğümün girişlerindeki değişken bağlantı ağırlıklarını derlemektir. İstenen bazı sonuçları elde etmek için, giriş bağlantılarının ağırlıklarını değiştirme işlemi uyma işlevi olarak adlandırabildiği gibi öğrenme kipi olarak da adlandırılabilir.

Danışmanlı ve danışmansız olmak üzere iki tip öğrenme türü vardır. Danışmanlı öğrenmede bir öğretmene ihtiyaç vardır. Öğretmen, bir veri alıştırma kümesi veya ağ sonuçlarının performansını derecelendiren bir gözlemci olabilir. Danışmanlı öğrenmede eğitilmiş sinirlere öğretme işaretini göndererek sinirler eğitilir. Bu işaretin bağlantısındaki ağırlıkları ayarlamakta kullanılır. Önemli öğrenme kurallarından bir kaç aşağıda örnek olarak verilmiştir:

Hebb Kuralı; İlk ve en iyi bilinen öğrenme kuralı Donald Hebb tarafından tanıtılmıştır. Temel kural: Eğer bir sinir başka bir sinirden bir giriş alırsa ve her ikisi de yüksek aktif ise (matematiksel olarak aynı işaretli), sinirler arasındaki boyut kuvvetlendirilir.


Hopfield Kuralı; Bu kural, kuvvetlendirme veya zayıflatmanın genliğini belirleyebilmesi ististası haricinde Hebb kuralıyla benzerdir. Buna göre, “eğer istenilen çıkış ve girişin her ikisi de aktif veya her ikisi de durgun ise, bağlantı boyutlarını öğrenme oranı kadar arttır, aksi halde boyutu öğrenme oranı kadar azalt”, (Öğrenme fonksiyonlarının çoğunun öğrenme oranı veya öğrenme sabiti için bazı koşulları vardır).

Delta Kuralı; En çok kullanılan kurallardan biri olan Delta kuralı, Hebb kuralının daha geliştirilmişidir. Bu kural bir sinirin gerçek çıkışı ile istenilen çıkış değeri arasındaki farkı azaltmak için giriş bağlantı güçlerini sürekli olarak geliştirme fikrine dayanır. Bu kural ağ hatasının karesini minimize etmek için bağlantı boyutlarını değiştirir. Hata bir önceki katmana geri çoğaltılır. Her bir zaman dilimi için bir hata şeklinde bu geri çoğaltma işlemi ilk katmana ulaşıncaya kadar devam eder. Bu tip ağ *İleri Beslemeli Ağ* olarak isimlendirilir, geri yayılım adını bu hata terimlerini toplama yönteminden türetir. Bu kural ayrıca Windrow-Hoff Öğrenme ve En Küçük Ortalamalar Karesi (Least Mean Square) Kuralı olarak da adlandırılır.

Eğimli İniş Kuralı; Bu kural Delta kuralına benzer çünkü transfer fonksiyonunun türevi bağlantı ağırlıklarına uygulamadan önce, Delta hatasını düzeltmek için kullanılır. Bu kural durağan bir noktaya çok bir şekilde yaklaşmasına rağmen sıkça kullanılır. Bir ağın farklı katmanları için öğrenme oranları, öğrenme işleminin daha hızlı olmasına yardımcı açıklamıştır. Bu test işleminde çıkışa yakın olan katmanların öğrenme oranından daha düşüktür. Giriş verilerinin güçlü bir modelden çıkarılmadığı uygulamalarda, bu işlem özellikle önemlidir.

Kohonen Öğrenme Kuralı; Kohonen tarafından geliştirilen bu yöntem biyolojik sistemlerdeki öğrenmeden esinlenilmiştir. Bu yöntemde sinirler öğrenmek için

elverişli durum veya ölçülerini güncellemek için yarışır. En büyük çıkış ile işlenen sinir, kazananı ilan eder ve komşularına bağlantı boyutlarını güncellemeleri için izin verilir (Elmas, 2003).



Şekil 1.12 Öğrenme yöntemlerine göre ağ yapıları (Elmas, 2003)

1.4.6 Yapay Sinir Ağlarının Oluşturulması

Yapay sinir ağları düğüm veya sinir olarak adlandırılan çok sayıdaki işlem elemanının bir araya gelmesinden oluşur. Psikolog Frank Rosentblatt'ın öğrenme yeteneğine sahip olan bir örnek tanıma aygıtını ortaya çıkarmış olduğu 1958 yılından bu yana, hiyerarşik sinir ağı en çok üzerinde çalışılmış olan bir ağ yapısı olmuştur. Bir hiyerarşik sinir ağı, düğümlerin sıralı bir şekilde art arda bağlanmasından oluşur. Bu tür ağların özelliği sahip oldukları basit dinamikleridir. Giriş katmanına bir işaret girerse, bu işaret sinirler arasındaki bağlantılar yoluyla diğer katmana iletilir. Giriş katmanının düğümleri tarafından öteki katmana iletilmeden önce bu işaret üzerinde basit bir işlem yerine getirilir. Bu süreç çıkış katmanına erişinceye kadar tekrar edilir.

Yapay sinir ağlarının düğümleri ve bağlantıları çok değişik biçimlerde bir araya getirilebilir. Ağlar bu düğüm ve bağlantı mimarilerine göre değişik isimler alırlar.

Yapay sinir ağ mimarileri, sinirler arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre birbirlerinden ayrılmaktadır. Buna göre yapay sinir ağları için,

- İleri beslemeli (feedforward)
- Geri beslemeli (feedback veya recurrent)

ağlar olmak üzere iki temel ağ mimarisi vardır.

Ağ içerisindeki düğümler katmanlar halinde yerleştirilir. İlk katmandaki girişe verilen bilgi ağ içinde ileriye doğru yayılır. Her katmandaki düğümlere sadece önceki katmandaki düğümlerden girişlere izin verilir. Bir düğüm kendinden sonraki herhangi bir düğüme bağlanabilirken kendisine asla bağlanmaz. Son katmandaki işaretler ağın çıkışıdır. Geri beslemeli veya tekrarlanan ağlarda en azından bir düğümün geriye yayıldığı bir dönüş bağlantısı vardır. Tekrarlanan ağlar da tamamen veya parçalı olarak geri besleme yollarına sahiptirler. Bu tür ağların tasarımları ve davranışları oldukça karmaşıktır.

Sinir ağlarında istenen sonucun elde edilmesi için ağın uyarlanabilir olması gerekir. Bunu sağlamak için uygun değerli aralıklar ve doğru bağlantılar seçilmelidir. Ağ bu şartları karşılayabilmek için sistemin davranışlarını öğrenmeli ya da kendi kendini örgütlemelidir. Öğrenme kalıcı yenilenmeler için gözlemleme veya eğitim faaliyetlerinden çıkan sonuçlar olarak tanımlanabilir. Öğrenme yapay sinir ağının ayrılmaz bir parçasıdır. Öğrenme; giriş değerlerine veya bu girişlerin çıkışlarına bağlı olarak ağın bağlantı ağırlıklarını değiştiren veya ayarlayan öğrenme kuralı ile gerçekleştirilir.


Ağların eğitimi için kullanılan öğrenme kuralları genellikle;

- Danışmanlı öğrenme (supervised learning),
- Danışmansız öğrenme (unsupervised learning)
- Pekiştirerek öğrenme (reinforcement learning)

olmak üzere üç öğrenme yöntemi başlığı altında toplanabilir.

Danışmanlı öğrenme kuralları, arzu edilen ağ çıkışının elde edilebilmesi için, çıkış hatasının düşürülmesinde ağırlıkların uyarlanabilir hale getirilmesini gerektirir. Danışmanlı öğrenmede her giriş değeri için istenen çıkış sisteme tanıtılır ve yapay sinir ağının giriş- çıkış ilişkisini gerçekleştirene kadar aşama aşama ayarlar. Danışmanlı öğrenmeye çok katmanlı perceptron (multilayer perceptron), geriye yayılım (backpropagation), delta kuralı, Widrow- Hoff veya en küçük karelerin ortalaması (least mean square) ve uyarlanabilir doğrusal eleman anlamına gelen ADALINE örnek olarak verilebilir.

Geri yayılım algoritması (Backpropagation); birçok uygulamalarda kullanılmış en yaygın öğrenme algoritmasıdır. Anlaşılması kolay ve tercih edilen öğretim algoritmasıdır. Bu algoritma ; hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri yayımlı öğrenme kuralı ağ çıkışındaki mevcut hata düzeyine göre her bir tabakadaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Bir geri yayımlı ağ modelinde giriş, gizli ve çıkış olmak üzere 3 katman bulunmakla birlikte, problemin özelliklerine göre gizli katman sayısını arttırabilmek mümkündür.



Şekil 1.13 Geri yayımlı yapay sinir ağının genel yapısı
(<http://www.backpropagation.netfirms.com/backprop.htm>)


Danışmansız öğrenmede bir danışman veya öğretmen, sinir ağına girişin hangi veri parçası sınıfına ait olduğunu veya ağın nerede iyi sonuç vereceğini söylemez. Ağ veriyi üyeleri birbirinin benzeri olan öbeklere yol gösterilmeksizin ayırır. Danışmansız öğrenme danışmanlı öğrenmeye göre çok daha hızlıdır. Ayrıca matematik algoritmaları da daha basittir. Danışmansız öğrenmeye yarışmacı öğrenme (competitive learning), Kohonen'in özörgütlemeli harita ağları (self-organizing), Hebbian öğrenme, Grossberg öğrenme gibi öğrenme kuralları örnek olarak verilebilir.

Yaparak öğrenme veya pekiştirerek öğrenme yönteminde ağ doğrudan gerçek ağ çıkışını vermez, ağ çıkışının iyi veya kötü olarak değerlendirmesini yapar. Performans bilgisi genellikle ikili sayıdır ve denetim hareketleri sırasının başarısını gösterir (Elmas, 2003).

Bu tez çalışmasında, renk reçetesi oluşturmada yapay sinir ağlarının Multi Layer Perceptron (MLP) ve Radial Basis Function (RBF) yöntemleri kullanılarak çeşitli modeller oluşturulmuştur.

1.4.6.1 Çok Katmanlı Sinir Ağı Yapısı (Multi Layer Perceptron-MLP)

Bir MLP bir giriş, bir çıkış katmanı ve aralarında belli bir sayıda gizli katmanlardan oluşur.



Şekil 1.14 Tipik bir MLP yapısı (<http://www.hindawi.com/journals/wcn/>)


Bir MLP’de iki temel işlem fazı vardır:

- h) Feedforward computation: X_i olarak tanımlanan network girişlerinden, $i=1, \dots, N$, ilk gizli katmanın çıkışları hesaplanır. Daha sonra bu değerler ikinci gizli katmana giriş olarak kullanılarak bu katmanın çıkışları hesaplanır. En sonunda, sistemin çıkışı elde edilir.
- i) Weight adaptation: Network’ün çıkışı elde edilmek istenen çıkışla karşılaştırılır. Bu iki değer arasındaki fark “error” olarak adlandırılır ve bu değer daha sonra çıkış katmanındaki ilk weight’ leri, daha sonra da önceki katmandakileri ayarlamak için kullanılır. Burada amaç error’ü azaltmaktır. Bu geri yönlü hesaplama “error backpropagation” olarak adlandırılır.

1.4.6.2 Radyal Tabanlı Fonksiyon (Radial Basis Function-RBF)

RBF, iki katmanlı bir network' tür. "Multi-Layer Sigmoidal Network" ile arasında iki temel fark vardır:

1. Gizli katmandaki aktivasyon fonksiyonu sigmoid değil, radial basis fonksiyondur.
2. Ayarlanabilir weight'ler sadece çıkış katında bulunur. Giriş katından gizli katmana olan bağlantılar sabittir (unit weights). Bunun yerine RBF'nin parametreleri ayarlanır.



Şekil 1.15 Radial basis function neural network (<http://www.hindawi.com/>)

1.4.7 Yapay Sinir Ağlarının Tekstilde Kullanımı

Günümüzde yapay sinir ağları tekstil endüstrisinde geniş bir kullanım alanına sahip değildir. Bununla birlikte tekstil alanında yapay sinir ağları üzerine yapılan araştırmalar her geçen gün artmaktadır. Yapay sinir ağları tekstilde genel olarak beş farklı alanda uygulama bulmuştur. Bunlar,

1. Yapay sinir ağıları 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 ağıları ile regresyon modellerinin tahmin güvenilirliğinin karşılaştırıldığı deneysel çalışmalara da rastlanmıştır.
2. Tekstil materyallerinin sınıflandırılması ve hata tanımlaması için yapay sinir ağlarının kullanımı sık rastlanan uygulamalar arasındadır.
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 yapay sinir ağıları uygulamaları arasındadır.
4. Makine ayarlarının önceden belirlenmesi hususunda da yapay sinir ağıları başvurulan bir tahmin tekniği olarak göze çarpmaktadır. Örme ve dokuma makinesi ayarlarının belirlenmesi, boyama şartlarının tespiti için kullanıldığı belirlenmiştir.
5. Yapay sinir ağıları, 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 (Balcı ve Oğulata, 2009).

Bishop (1991), renk reçetesi oluşturulması ile ilgili basit bir yapay sinir ağı kurmaya çalışmıştır. Normalize edilmiş tristimulus değerlerine dayanan bir yaklaşımı simüle etmek için geri yayılma ağını (backpropagation) kullanmıştır. Bu yaklaşımın avantajı tristimulus değerleri ile girdi değişkeninin sayısının 3 ile sınırlanmasıdır. Bu

durumda bu ağ topolojisi çok basittir: 3 girdi, 8 ve 16 gizlenen ve renk sayısı kadar çıktı nöron birimlerinden oluşur. Fakat sonuçların pratik ile uyumu çok düşüktür.

Jasper, Kovacs ve Berkstresser (1993), 3 ticari boyarmadde kullanarak toplam 62 tane olmak üzere tekli, ikili ve üçlü boyarmadde karışımları ile boyama reçeteleri üretmişlerdir. 3 farklı model ile boyama reçeteleri elde edilmiştir: Beer yasası modeli (Model I), modifiye lineer model (Model II) ve sinir ağı modeli (Model III). Sinirsel ağ modelinde geri yayılım yaklaşımı kullanılmıştır. Aktivasyon fonksiyonu olarak sigmoid fonksiyon kullanılmıştır. Öğrenme hızı 0,01 olarak alınmıştır. Sonuç olarak Beer yasasından sapmalardan dolayı ortalama relatif hata Model I’de %31 olarak saptanmıştır. Model II yalnızca 3’lü boyarmadde karışımları için %9 ortalama relatif hata vermiştir. Model III %2.6 relatif hata ile diğer modellerin tümünden iyi sonuç vermiştir.

Westland (1998), çok katmanlı sinir ağı yapısını (MLP) kullanarak reçete tahmini yapmıştır. 400-700 nm bölgesinde 10 nm aralıklarla reflektans değerlerine karşılık gelen 31 tane çıktı tabakası nöron birimi ve 6 baskı mürekkebi için konsantrasyonları gösteren 6 girdi tabakası nöron birimi kullanılmıştır. Gizlenen tabakadaki nöron sayısı 6, 7 ve 8 alınarak etkisi incelenmiştir. Momentum terimi 0.1 olarak sabit alınmıştır. Renk karışımları opak grafik üzerine basılmıştır. 123 örnekten oluşan öğrenme kümesi ve 40 örnekten oluşan test kümesi olmak üzere 163 renk örneği kullanılmıştır. Diğer ağlarda eğitimde kullanılan veri seti sayısı 123 yerine 40, 60, 80 olarak seçilmiş ve ağın performansı bir de bu verilerle denenmiştir. Çalışmanın sonunda girdi sayısının ağ performansı üzerinde etkili olduğu fakat gizli katman sayısının fazla etkili olmadığı belirtilmiştir.

Ertuğrul ve Uçar (2000), çalışmalarında pamuklu düz örgü kumaşların patlama mukavemetlerini, sinir ağı ve bulanık mantık yaklaşımlarını kullanarak üretimden önce tahmin etmeye çalışmışlardır. Kumaş patlama mukavemetini etkileyen bir çok parametre olmakla birlikte, kumaş ağırlığı, iplik kopma mukavemeti ve kopma uzaması girdi değişkenleri olarak kullanılmıştır. Sinir ağı çok katmanlı, ileri beslemeli ağ yapısındadır, geri yayımlı öğrenme kuralı (backpropagation)

kullanılarak eğitilmiştir. Çalışma sonucunda, incelenen sistemlerin yeterli tahmin gücüne sahip olduğu belirlenmiştir.

Westland (2002), çalışmasında reçete hesaplanmasında konvansiyonel bir sistem olan Kubelka- Munk teorisine alternatif olarak, yapay sinir ağları ile reçete hesaplanması üzerinde durmuştur. Yapay sinir ağlarının, renklendirici konsantrasyonlarından spektral reflektans değerlerini tahmin yeteneği araştırılmıştır. Bunu yaparken oluşturulan yapay sinir ağının gizli tabakadaki nöron sayısı ve öğrenme oranı parametreleri değiştirilerek ağın performansı bu parametrelerin değişkenliğine göre de test edilmiştir. Yapay sinir ağının eğitiminde geri yayılım algoritması kullanılmıştır. Momentum terimi 0,9; öğrenme oranı 0,2 olarak sabitlenmiştir. Sinir ağları her biri için 500.000 toplam devir ile gizli tabakada 5, 10, 15 ve 20 nöron sayıları kullanılarak eğitilmiştir. Ağ en iyi performansına gizli tabakada 10 nöron birimi olduğunda ulaşmıştır. Nöronların sayısı 10'u aştığında test kümesindeki hatanın artmaya başladığı görülmüştür.

Cheng ve Lam (2003), birleştirilmiş ipliklerin fiziksel özelliklerini regresyon ve sinir ağı teknikleri ile tahmin etmeye çalışmışlardır. Birleştirilmiş iplikler için parametrelerin önem derecelerini test ederek, birleşme için en uygun koşulları belirlemişlerdir. Sinir ağı ile yapılan tahminlerin, regresyon analizine göre daha yüksek doğrulukta olduğu sonucuna ulaşmışlardır.

Oğulata, Şahin ve Balcı (2006), çalışmalarında polyester, viskoz, elastan karışımı dokuma kumaşın, elastikiyet ve kalıcı uzama özelliklerini, farklı girdi değişkenleri kullanarak, yapay sinir ağları ve doğrusal regresyon modelleri ile tahminlemişlerdir. Toplam 45 data setinden, 27 tanesi eğitim, 5 tanesi durdurma ve 13 tanesi test için kullanılmıştır. Çalışmanın sonucuna göre; kumaşın elastikiyet değerlerini tahminlemede her iki model de kullanılabilir. Bununla birlikte kalıcı uzama özelliği için iki modelin tahminleme gücü, atkı ve çözgü yönüne göre değişkenlik göstermektedir.

Senthilkumar ve Selvakumar (2006), çalışmalarında reaktif boyamada istenilen renk derinliğinin elde edilebilmesi için boyamanın doğru sürelerle yapılması gerektiğini vurgulamışlardır. Pamuklu kumaşlarda, reaktif boyalarla yapılan işlemlerde bu süreler yapay sinir ağları kullanılarak tahmin edilmiştir. Çalışmada 3 farklı boyarmadde ve çektirme yöntemi kullanılmıştır. Ağ 6 farklı girdi ve 2 farklı çıktı ile kurulmuştur. Girdiler boyanacak kumaşın K/S değeri, kumaş üzerindeki toplam boyarmadde, tuz- soda konsantrasyonu ve boyanan kumaşın K/S değeridir. Çıktı olarak ise boyama zamanı ve fikse zamanı hedeflenmiştir. Sinir ağı geri yayımlı öğrenme kuralı (backpropagation) kullanılarak eğitilmiştir. Ağdan elde edilen sonuçlar, istenilen renk derinliğinin elde edilebilmesi için gerekli zamanın tahmininde ortalama %1 hata vermiştir. Eğitilmiş ağ, ağı eğitmede kullanılan girdilerin dışında girdilerle test edildiğinde bile yine aynı ortalama % hatayı vermiştir.

Mahlmann, Hermanns, Veit ve Gries (2007), PES kesik elyafın eğirme tutumunun sinir ağları ile önceden belirlenmesi üzerine bir çalışma yapmışlardır. PES elyafının, elyaf tipi ve nominal değerleri aynı olmasına rağmen, üreticisi değiştiğinde son derece değişken çalışma tutumu gösterdiğini ve bu problemlerin sonuçta makinelerde optimal ayarları araştırmak gibi randıman düşüşlerine yol açabilecek çalışmalara neden olduğu gibi, kalite kayıplarına da neden olabileceğini vurgulamışlardır. Çalışmanın sonucunda, open-end rotor iplik eğirme prosesinde önceden belirlenmiş makine ayarları, işletme malzemesi, elyaf değerleri ve şerit kalite değerleri yardımıyla elyafın çalışma tutumunun önceden belirlenebileceği tespit edilmiştir.

Senthilkumar (2007), çalışmasında vinil sülfon reaktif boyarmaddeleriyle boyanan pamuklu kumaşlar için geliştirilen sinir ağı ile CIELab değerlerinin tahminlenmesi üzerinde durmuştur. Geliştirilen sinir ağı çok katmanlı, ileri beslemeli ağ yapısındadır. Ağın eğitimi esnasında; boyanacak kumaşın beyazlık indeksi, tuz ve alkali konsantrasyonu, boyarmadde konsantrasyonu(%), kumaş üzerine fikse olan toplam boyarmadde miktarı (%) ve boyama süresi girdi parametreleri olarak; CIELab değerleri ise çıktı parametreleri olarak alınmıştır. Vinil sülfon boyarmaddesi ile

boyanmış 114 adet örnek alınmıştır. Bu örneklerden 108 tanesi ağın eğitimi için, 6 tanesi de ağın test edilmesinde kullanılmıştır. Ağdan elde edilen sonuçlar, vinil sülfon boyarmaddesi için Lab değerlerinin tahminlenmesinde ortalama %2 hata vermiştir.

Balcı, S. N. Oğulata, Şahin ve R. T. Oğulata (2008), çalışmalarında boyası sökülmüş pamuklu mamulün CIELab değerlerini bir yapay sinir ağı tekniği olan Levenberg-Marquardt (LM) ile tahminlemeye çalışmışlardır. Sırasıyla; yakma, merseizasyon, ağartma, yıkama ve kurutma ön işlemlerinden geçmiş olan pamuklu dokuma kumaş ile çalışmışlardır. Ön işlem görmüş örnekler daha sonra 5 ticari reaktif boyarmadde kullanılarak boyanmıştır. Bu çalışmada sökme işlemlerinin etkisini incelemek amacıyla L^* ve ΔE değerleri üzerinde durulmuştur. a^* , b^* , C ve h değerleri ise genellikle söküm işleminden sonra tekrar boyama reçetelerinin eşlenmesinde kullanılmıştır. Data setleri girdi olarak bazı boyama (boyamanın türü, sökme işleminden önce ölçülen L^* , a^* , b^* gibi orijinal renk değerleri) ve sökme parametrelerinden (indirgen maddenin türü, kostik ve indirgen maddenin konsantrasyonu, çalışma sıcaklığı) oluşmaktadır.

En uygun modeli belirleyebilmek için farklı ağ yapıları kurulmuştur. Bu ağ yapılarında; girdi sayıları, gizli tabakadaki nod sayıları ve durdurma kriteri olan MSE değeri farklılık göstermektedir. Denemeler sonunda L^* için, 8 girdi ve gizli tabakada 85 nod içeren, MSE değeri 0.001 olan sinir ağı modelinin en iyi tahminleme sonuçlarını verdiği görülmüştür. ΔE için ise, 10 girdi ve gizli tabakada 70 nod içeren ve MSE değeri 0.001 olan sinir ağı modelinin en iyi tahminleme sonuçlarını verdiği görülmüştür. Sökülmüş örneklerin L^* değerleri %1.2 hata payı ile tahminlenmiştir.

Sonuç olarak, sökme işleminin parametreleri sinir ağına girdi olarak beslenir ve çıktı parametreleri olan boyası sökülmüş örneğin L^* ve ΔE değerleri sökme işlemi yapılmadan bu sinir ağı modeli sayesinde elde edilebilmektedir. Tahminleme sonrasında uygun işlem parametreleri seçilebilmekte ve işleme başlanabilmektedir.

Golob, Osterman ve Zupan (2008), tekstil baskıcılığında istenilen rengin eldesi için uygun boyarmaddelerin belirlenebilmesinde yapay sinir ağlarının kullanımı üzerine bir çalışma yapmışlardır. 10 adet boyarmadde ile oluşturulan 1430 adet baskılı örnek sinir ağlarının eğitiminde kullanılmıştır. Reflektans değerleri girdi dataları olarak kullanılmakla birlikte baskılı her örnek için boyarmadde konsantrasyonları bilinmektedir. En iyi modelin belirlenebilmesi için sinir ağı parametrelerinde bazı varyasyonlar yapılmıştır. Ayrıca girdi ve çıktı datalarına, sistemin öğrenme yeteneğini geliştirmek amacıyla bazı modifikasyonlar uygulanmıştır. Çalışmada temel olarak alınan 1430 adet viskoz kumaş örneği ya tek çeşit boyarmadde ile ya da iki boyarmaddenin kombinasyonunu içerecek şekilde basılmıştır. Her örnek 16 girdi değeri (400-700 nm, 20 nm aralıklarla) ve 10 çıktı değeri ile temsil edilmektedir. Çıktı değerleri “1” ve “0” lardan ibarettir. Bu değerler bir boyarmaddenin, boya kombinasyonu içerisinde olup olmadığını gösterir.

Sonuç olarak iki boyarmadde kombinasyonunu içerecek şekilde basılan 1350 örnekte sinir ağının doğru tahminleme oranı %83,8 olmuştur. 1350 örnekten sadece 7'sinde ağ her iki boyarmadde için de yanlış tahminlerde bulunmuştur. Diğer yöntemlere kıyasla, başlangıç aşamasında bir sinir ağı modelini eğitmek ve optimal parametreleri bulmak daha fazla çaba gerektirmektedir. Buna karşın, eğitim aşaması tamamlandığında sinir ağı yaklaşımı yeni, bilinmeyen örnekleri hızlı ve kolay bir şekilde belirleyebilmektedir.

Balcı ve Oğulata (2009), çalışmalarında boyanmış kumaşlarda kimyasal apre uygulamaları sonucunda oluşabilecek renk değişimini ve CIELab değerlerini yapay sinir ağlarını kullanarak tahminlemeye çalışmışlardır. 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 kullanılarak tahmin edilmeye çalışılmıştır. Toplam 2106 veriden oluşan girdi seti %75'i eğitim, %10'u çapraz durdurma ve %15'i test olacak şekilde sınıflandırılmıştır. Çok katmanlı, ileri beslemeli ağ yapısı ve geri yayımlı öğrenme kuralı ile ağlar oluşturulmuştur. Aktivasyon fonksiyonu sigmoid olarak seçilmiştir.

Çalışmada ilk olarak, boyanmış tekstil materyalinin CIELab değerleri ölçülüp, boyama + apre sonrasındaki renk farkı değerleri hesaplanmıştır. Daha sonra bu amaç için oluşturulan 2106 girdi kullanılarak, yapay sinir ağları tekniği ile apre olmuş numunelerin CIELab değerlerini ve apre sonrası renk değişimini tahmin edebilecek uygun modeller kurulmuştur.

Kurulan ağların korelasyon katsayılarının ve R^2 değerlerinin oldukça iyi olduğu belirlenmiş, tahmin değerlerinin gerçek değerlere göre kabul limitleri içerisinde sapma gösterdiği hesaplanmıştır. Bu sonuç, kurulan yapay sinir ağ modellerinin, apre uygulamaları sonrası boyanmış kumaşa meydana gelebilecek renk değişimlerinin tahmininde kullanılabileceğini göstermiştir.

Yang, Zhu ve Pan (2010), Kubelka-Munk teorisi hakkında detaylı bir çalışma yapmışlardır. Işığı yansıtan materyallerde, renk karışımları için temel teori olarak Kubelka-Munk tek-sabit/iki-sabit teorileri renk bilim ve teknolojisinde önemli bir rol oynamaktadır. Uygulamada bu teorilerin bazı eksiklikleri vardır. Bu çalışmada bir seri sistematik deneme, veri işleme ve analizi ile teoriler kontrol edilmiştir. Deneysel kanıtlarla, bazı çelişkiler ortaya çıkarılmıştır. Bazı problemlerle ilgili, geleneksel görüşlerden farklı olan açıklamalara yer verilmiştir.

Reaktif boyarmaddelerle çalışmışlardır (Red C-2G, Yellow C-RG, Blue C-R). Sadece Red C-2G'den elde edilen verilere yer verilmiştir. Diğer boyarmaddelerde de benzer sonuçlara ulaşılmıştır. Sodyum karbonat ve sodyum klorit boyamada kullanılan yardımcı maddelerdir. Turbid substrat olarak, donuk beyaz, ışığı yansıtan dimi bir kumaş seçilmiştir. Boyamaların ardından spektrofotometrik ölçümler yapılmıştır.

Ölçümler ve değerlendirmeler sonucunda, boyanmış kumaşın K (absorbsiyon) ve S (yansıma) değerleri arasında yüksek fakat negatif yönde bir korelasyon bulunduğu görülmüştür. Boyarmadde konsantrasyonu arttığında, K yükselmekte fakat S düşmektedir. Boyarmaddeler için karışım yasasında, K ve S arasındaki ters

korelasyon dikkate alınmamıştır. Kumaş boyamada genellikle, K-M tek sabit teorisi kullanılmaktadır. Sonuçlar bu teoriyle de çelişmektedir.

1.4.7.1 Renk Reçetesi Tahminlenmesinde Sinir Ağlarının Kullanımı


Renk reçete tahminlemesi; verilen bir referans renk ile aynı rengi üretmek için hangi boyarmaddelerin hangi konsantrasyonlarına ihtiyaç duyulduğunu tahmin etmektir. İyi bir tahminleme yapabilmek deneyimli boya uzmanları için bile zordur. Reçete tahmini; klasik reçete çıkarma sistemine göre veya bilgisayarlı reçete çıkarma sistemine göre yapılabilir. Klasik reçete çıkarma sisteminde bir boya uzmanı deneyimlerine dayanarak verilen renge yakın bir reçete tutturmaya çalışır, bilgisayarlı reçete çıkarma sistemleri ise yaygın olarak bilinen doğrusal modele (Kubelka-Munk modeli) veya doğrusal olmayan (sinir ağları) modele dayanabilir.

Genel bilgisayar ile boyarmadde konsantrasyon hesabı sistemleri Beer Yasası'na dayandırıldı. Beer Yasası'na göre konsantrasyon ve boyarmadde absorbansı arasında lineer bir ilişki vardır ve renk absorpsiyon ölçümleri Kubelka-Munk denklemine (12) göre yapılmaktadır.

$$A_1 \times C_1 + A_2 \times C_2 + A_3 \times C_3 = K/S = (1-R)^2/2R \quad (12)$$

Burada, A_i ; i.inci boyarmaddenin absorbtivite katsayısı, C_i ; i.inci boyarmaddenin konsantrasyonu, K ; verilen dalga uzunluğu için absorpsiyon katsayısı, S ; verilen dalga uzunluğu için saçılma katsayısı, R ; refleksiyondur.

Bu esasa dayanan modellerde bir çözeltideki absorblayıcı türlerin karışımı için spektrumun, tek başına spektraların toplamına eşit olduğu tahmin edilir. Fakat boyarmaddelerin karışımları için bu tahmin yapılamaz. Aşağıdaki şekilde de görüldüğü gibi 3 absorbans spektrasının ideal olarak birbirine ilavesi deneysel olarak ölçülen spektruma benzememektedir (Jasper ve ark., 1993).



Şekil 1.16 Üçlü boyarmadde karışımının etkileri. 3 absorbans spektrasının toplamı üçlü boyarmadde karışımının deneysel olarak gözlenen spektrasına denk gelmez.

Çözeltideki boyarmadde karışımlarının spektrası çözelti içindeki çeşitli heterojen etkileşimlerden dolayı boyarmaddelerin tek başlarına spektralarının toplamı değildir. Çözelti içindeki bu heterojen etkileşimler farklı boyarmadde büyüklüklerine bağlı olarak değişen boya-boya ve boya-tuz etkileşimleri, çözelti sıcaklığına ve pH varyasyonlarına bağlı olarak boyarmadde absorbtivitelerindeki farklılıklar olarak sıralanabilir. Bu heterojen etkileşimler boyarmadde konsantrasyonu ve absorbansı arasındaki doğrusallığı bozar. Bu nedenle çoklu boyarmadde karışımlarında konsantrasyon tahmini için yeni bir lineer olmayan model geliştirilmesine ihtiyaç duyulmuştur. Bu amaçla sinir ağlarının kullanımının iyi sonuçlar verdiği bulunmuştur. Bunun nedeni sinir ağlarında kullanılan aktivasyon fonksiyonunun doğrusal olmayan bir yapıya sahip olmasıdır.

Bununla birlikte bilgisayarlı reçete hesaplama sistemleri bir ön hazırlık işlemini gerektirir. Bu ön hazırlık işlemi zaman alıcı ve iş gücü harcamalı bir işlemdir. Ön işlemde temel kalibrasyon boyamaları çeşitli konsantrasyon aralıklarında örnek renklerin hazırlanıp spektral reflektans değerlerinin spektrofotometrelerde okunmasını gerektirir. Ayrıca bu ön hazırlıkta örnekler laboratuarda hazırlanırken,

elde edilen veriler işletme şartlarına uymayabilir (Westland, 1998). Sinir ağları ise üretim örneklerini kullanabilir, özel kalibrasyon boyamalarına gerek duymaz. Ayrıca daha önceden de bahsedildiği gibi Beer yasasına dayanan sistemlerde konsantrasyon-absorbans arasındaki ilişkide doğrusallığı bozan pek çok faktör göz ardı edilmektedir. Bu ise reçete hesabında hata payını artırmaktadır. Doğrusallığı bozan pek çok faktörün de hesaba katıldığı sinir ağlarına dayanan sistemde reçete hesabında hata payı azalmaktadır.

1.5 Bulanık Mantık

Endüstriyel bir süreç denetiminden; sistemin güvenliği ve kararlılığını sağlaması, kolay, anlaşılır, tamir edilebilir ve değiştirilebilir olması, sistemin performansını istenen seviyeye çıkarması, yatırım ve işletme açısından ucuz olması istenir. Bu koşulların gerçekleştirilmesi için denetlenecek sistemin yapısının ve dinamik özelliklerinin çok iyi bilinip matematiksel modellemesi gerekir. Bazı sistemlerin matematiksel modellemesi mümkün olmayabilir. Sistemin değişkenleri matematiksel modelleme yapılabilecek kadar kesin olarak bilinmeyebilir veya bu değişkenler zaman içinde değişiklik gösterebilir.

Bazı sistemlerde modelleme doğru şekilde yapılsa bile elde edilen modelin denetleyici tasarımında kullanımı karmaşık problemlere ve oldukça yüksek maliyete neden olabilir. Bu nedenle, bazı denetim algoritmalarının belirsiz, doğru olmayan, iyi tanımlanmamış, zamanla değişen ve karmaşık sistemlere uygulanması mümkün olmayabilir. Bu durumda ya hiç çözüm üretilememekte ya da elde edilen denetleyicinin performansı yeterince iyi olmamaktadır.

Bu gibi durumlarda genellikle bir uzman kişinin bilgi ve deneyimlerinden yararlanılma yoluna gidilir. Uzman kişi az, çok, pek az, pek çok, biraz az, biraz çok gibi günlük hayatta sıkça kullanılan dilsel niteleyiciler doğrultusunda bir denetim gerçekleştirir. Bu dilsel ifadeler doğru bir şekilde bilgisayara aktarılırsa hem uzman kişiye ihtiyaç kalmamakta hem de uzman kişiler arasındaki denetim farkı ortadan kalkmaktadır. Böylece denetim mekanizması esnek bir yapıya kavuşmaktadır.

Temeli insanın herhangi bir sistemi denetlemedeki düşünce ve sezgilerine bağlı davranışının, benzetimine dayanmaktadır. Dolayısıyla bir insan bir sistemin bulunduğu gerçek durumdan, istenilen duruma götürmek için sezgilerine ve deneyimlerine bağlı olarak bir denetim stratejisi uygulayarak amaca ulaşmaktadır.

İşte bulanık denetim bu tür mantık ilişkileri üzerine kurulmuştur. Bulanık mantık için, matematiğin gerçek dünyaya uygulanması denilebilir. Çünkü gerçek dünyada her an değişen durumlarda değişik sonuçlar çıkabilir.

Bulanık mantık yaklaşımı, makineler insanların özel verilerini işleyebilme ve onların deneyimlerinden ve önsezilerinden yararlanarak çalışabilme yeteneği verir. Bu yeteneği kazandırırken sayısal ifadeler yerine sembolik ifadeler kullanır. İşte bu sembolik ifadelerin makinelere aktarılması matematiksel bir temele dayanır. Bu matematiksel temel Bulanık Mantık Kümeler Kuramı ve buna dayanan Bulanık Mantıktır.

Bulanık mantık denetleyicinin temeli bu tür sözlü ifadeler ve bunlar arasındaki mantıksal ilişkiler üzerine kurulmuştur. Bulanık mantık denetleyici uygulanırken sistemin matematiksel modellenmesi şart değildir.

Sözel ifadelerin bilgisayara aktarılması matematiksel bir temele dayanmaktadır. Bu matematiksel temel, bulanık kümeler kuramı ve bulanık mantık olarak adlandırılır. Bulanık mantık bilinen klasik mantık gibi $(0, 1)$ olmak üzere iki seviyeli değil, $[0, 1]$ aralığında çok seviyeli işlemleri ifade etmektedir.

Örneğin odadaki klimanın motoru otomatik olarak değil de, bir insan tarafından denetlendiği varsayılın; oda sıcaklığı biraz arttıysa işletmen motorun hızını biraz artıracaktır, oda sıcaklığı çok düşüyse motor hızını çok azaltacaktır. Burada kullanılan “biraz”, “çok” terimleri dilsel terimler olup “bulanık değişkenler” olarak isimlendirilirler. Bulanık mantık denetimi dilsel olarak tanımlanmış denetim stratejisini uzman tabanlı otomatik denetim algoritmasına çevirir. Deneyimler bulanık mantık denetimi ile elde edilen çıkış performansının klasik yöntemlerle elde

edilene göre daha iyi olduğunu göstermiştir. Özellikle sistemin karmaşık olduğu ve analizinin klasik yöntemlerle yapılamadığı ve bilgilerin niteliklerinin belirsiz veya kesin olmadığı durumlarda bulanık mantık denetim yöntemi çok uygun olmaktadır.

Bu yaklaşım ilk defa Amerika Birleşik Devletlerinde düzenlenen bir konferansta 1956 yılında duyurulmuştur. Ancak bu konudaki ilk ciddi adım 1965 yılında Lotfi A. Zadeh tarafından yayınlanan bir makalede bulanık mantık veya bulanık küme kuramı adı altında ortaya koyulmuştur. Zadeh bu çalışmasında insan düşüncesinin büyük çoğunluğunun bulanık olduğunu, kesin olmadığını belirtmiştir. Bu yüzden 0 ve 1 ile temsil edilen boolean mantık bu düşünce işlemini yeterli bir şekilde ifade edememektedir. İnsan mantığı, açık, kapalı, sıcak, soğuk, 0 ve 1 gibi değişkenlerden oluşan kesin ifadelerin yanı sıra, az açık, az kapalı, serin, ılık gibi ara değerleri de göz önüne almaktadır. Bulanık mantık klasik mantığın aksine iki seviyeli değil, çok seviyeli işlemleri kullanmaktadır. Ayrıca Zadeh insanların denetim altında, mevcut makinelerden daha iyi olduğunu ve kesin olmayan dilsel bilgilere bağlı olarak etkili kararlar alabildiklerini savunmuştur. Klasik denetim uygulamalarında karşılaşılan zorluklar nedeniyle, bulanık mantık denetimi alternatif yöntem olarak çok hızlı gelişmiş ve modern denetim alanında geniş uygulama alanı bulmuştur.

Bulanık mantığın genel özellikleri Zadeh tarafından şu şekilde ifade edilmiştir;

- Bulanık mantıkta, kesin değerlere dayanan düşünme yerine, yaklaşık düşünme kullanılır.
- Bulanık mantıkta her şey $[0,1]$ aralığında belirli bir derece ile gösterilir.
- Bulanık mantıkta bilgi büyük, küçük, çok az gibi dilsel ifadeler şeklindedir.
- Bulanık çıkarım işlemi dilsel ifadeler arasında tanımlanan kurallar ile yapılır.
- Her mantıksal sistem bulanık olarak ifade edilebilir.
- Bulanık mantık matematiksel modeli çok zor elde edilen sistemler için çok uygundur.

Bulanık mantık tam olarak bilinmeyen veya eksik girilen bilgilere göre işlem yapma yeteneğine sahiptir (Elmas, 2007).

1.5.1 Bulanık Sistemlerinin Gelişimi

Geçmiş birkaç yıl içinde özellikle Japonya, Amerika ve Almanya’da yaklaşık 1000’den fazla ticari ve endüstriyel bulanık sistemleri başarıyla gerçekleştirilmiştir. Yakın gelecekte ticari ve endüstriyel uygulamalarda dünya çapında önemli oranda arttığı görülecektir.

Bulanık mantığın ilk uygulaması, Mandani tarafından 1974 yılında bir buhar makinesinin bulanık denetiminin gerçekleştirilmesi olmuştur. 1980 yılında bir Hollanda şirketi çimento fırınlarının denetiminde bulanık mantık denetimi uygulamıştır. 3 yıl sonra Fuji elektrik şirketi su arıtma alanları için kimyasal püskürtme aleti üzerine çalışmalar yapmıştır. 1987’de ikinci IFSA kongresinde ilk bulanık mantık denetleyicileri sergilenmiştir. Bu denetimler 1984 yılında araştırmalara başlayan Omron şirketinin 700’den fazla yaptığı uygulamaları içermektedir. 1987 yılında ise Hitachi takımının tasarladığı Japon Sendai metrosu denetleyicisi çalışmaya başlamıştır. Bu bulanık mantık denetim metroda daha rahat bir seyahat, düzgün bir yavaşlama ve hızlanma sağlamıştır. 1989 yılında Omron şirketi Japonya’nın Harumi şehrinde bulunan çalışma merkezinde yapmış olduğu bulanık sonuç-board’la yapılan depolama, tekrar etme ve bulanık sonuçlarını elde etmek için kullanılan (RISC) bilgisayara dayalı olan çalışmaları tanıtmıştır.

Bulanık kuramının uygulamalarının ürünleri Japonya’da 1990 yılında tüketicilere sunulmuştur. Örneğin, bulanık denetimli çamaşır makinesi, bu makine çamaşırın cinsine, miktarına, kirliliğine göre en etkili çamaşır yıkama ve su kullanım programını seçebilmektedir.

Bulanık mantık uygulamalarına diğer bir örnek arabalarda yakıt püskürtme ve ateşleme sisteminin denetimidir. Ayrıca, elektrik süpürgesi, televizyon ve müzik kümeleri gibi aygıtlarda da bulanık mantık denetim kullanılmaktadır.

1993 yılında Sony, The Palmtop sistemini tanıtmıştır. Burada bulanık mantıkla elle yazılan kanji karakterlerinin makine tarafından tanınması sağlanmıştır. Örneğin eğer 253 yazılırsa, burada Sony Palmtop S harfinden 5 sayısını ayırt edebilmektedir.

Bulanık mantık uygulamaları, ısı, elektrik akımı, sıvı gaz akımı denetimi, kimyasal ve fiziksel süreç denetimlerinde kullanılmaktadır.

Bulanık mantık yaklaşımı uygulandığında öncelikle problemin özellikleri tanımlanır. Bulanık mantık yaklaşımlarının kullanıldığı sistemler klasik sistemlere göre daha etkin ısı ve hız denetimi yapabilmektedir. Ayrıca, enerji tasarrufu sağlanmakta ve aygıt ömrü uzamaktadır.

Bulanık sistemlerde denetim kurallarının tanıtımı genellikle daha kolay ve basittir. Genel olarak bulanık mantık denetleyiciler daha az kural gerektirmekte ve daha yüksek performans sağlamaktadırlar.

Bulanık mantık işlemleri problemin analiz edilmesi ve tanımlanması, kümelerin ve mantıksal ilişkilerin oluşturulması, mevcut bilgilerin bulanık kümelere dönüştürülmesi ve modelin yorumlanması aşamalarından oluşmaktadır. Birçok önkoşul kullanılarak bulanık mantığın problemi çözüme götürüp götürmeyeceğine karar verilebilir. Bu önkoşullara sonucun tutarlılık oranı ve verilerin belirlilik ölçüleri de dahildir.

Öncelikle çözülecek problem için bulanık mantık yaklaşımının doğru bir seçenek olup olmadığına karar verilir. Eğer uygulanacak sistemin davranışı kurallarla ifade edilebiliyorsa veya karmaşık bir matematiksel işlem gerektiriyorsa, bulanık mantık yaklaşımı uygulanabilir. Aksi takdirde bulanık mantık ile elde edilen sonuçlar büyük olasılıkla istenilen değerleri vermeyecektir.

Sistemin her bir çıkış ve giriş değişkenleri için üyelik işlevi tanımlanmalıdır. Üyelik işlevinin sayısı sistemin davranışına bağlı olmakla birlikte, aynı zamanda tasarımcı seçimine de bağlıdır. Kaç tane kural gerektiğine tasarımcı karar verir.

Bulanık mantık kuramının en büyük özelliği ‘klasik’ bilgide olduğu gibi sayılardan çok sembolik bilgilerin kullanılmasıdır. Bu bilgi kavramları nesneleri düşünürken bir insanın göz önünde bulundurduğu olguların aynılarını temsil eder. Bu

sayısal işlem yöntemlerinin kullanılmasını dışlamaz, ancak sonuçların incelenmesi genellikle sembole dayalı olarak yapılır. Bulanık mantıkta bulunan ikinci bir kavram da klasik algoritma metotlarının tersine ‘tecrübeye dayalı bilgi’ metotları kavramıdır.

Bulanık mantığın bir başka özelliği de işlenen verilerin ve bilgilerin belirsiz, eksik, yanlış ve hatta çelişkili olduğu durumlarla yetinmesidir. Bulanık mantık çok karmaşık bir problemi tamamen çözmesine de etkili metotlar geliştirir.


Bulanık mantık ile tasarlanan ürünlerin kullanımı, tasarlanması, denenmesi daha kolay ve standart sistemlere göre daha iyi bir denetim sağlamaktadır. Ayrıca bulanık mantığın uygulamaya geçirilişi kolay, hızlı ve ekonomiktir (Elmas, 2007).

1.5.2 Bulanık Küme Kuramı ve Bulanık Mantık

Klasik küme kuramında bir eleman o kümenin ya elemanıdır ya da değildir. Hiçbir zaman kısmi üyelik olmaz. Nesnenin üyelik değeri 1 ise kümenin tam elemanı, 0 ise elemanı değildir. Başka bir deyişle klasik veya yeni ürün kümelerinde elemanların üyelikleri $\{0,1\}$ değerlerini alır. Bulanık mantık, insanın günlük yaşantısında nesnelere verdiği üyelik değerlerini, dolayısıyla insan davranışlarını taklit eder. Örneğin elini suya sokan bir kişi hiçbir zaman tam olarak ısısını bilemez, onun yerine sıcak, az sıcak, soğuk, çok soğuk gibi dilsel niteleyiciler kullanır.

Klasik kümelerle örnek Şekil 1.17’de verilmiştir. Eğer sıcaklık 20°C’nin altına düşerse sıcak değildir. Yani klasik mantık kuramına göre 19,5°C sıcak değildir. Doğal olarak bu mantığın hiçbir esnekliği yoktur. Gerçek dünyada ise sınırlar bu kadar keskin değildir. Endüstriyel denetleyici için bu durum ele alınır, denetleyicideki fiziksel büyüklüklerin dahil olduğu kümeler birbirlerinden böyle keskin sınırlarla ayrılmışlarsa denetim çıktısının ani değişiklikler göstermesi kaçınılmaz olacaktır. Bir de üyelik durumunun belirsizliği söz konusudur. Çok sık olarak, gerçek fiziki kelimelerle karşı karşıya gelen nesnelerin kümeleri, üyeliklerin önkoşullarını tam olarak tanımlayamaz. Örneğin, hayvanlar kümesi açıkça köpekleri, atları, kuşları vb. ve onların üyeliklerini kapsar. Fakat bakteriler vb. hayvanlar kümesiyle ilişkide belirsiz yapılara sahiptirler. Gerçek küme tanımlaması, bilginin

iletişimi, insan düşüncesindeki özellikle modellerin tanınması, soyut düşünce alanlarında önemli rol oynar.



Şekil 1.17 Sıcaklık için bir keskin küme örneği

Klasik kümelerin aksine bulanık kümelerde elemanların üyelik dereceleri $[0,1]$ aralığında sonsuz sayıda değişebilir. Bunlar üyeliğin derecelerinin devamlı ve aralıksız bütünüyle bir kümedir. Keskin kümelerdeki soğuk-sıcak, hızlı-yavaş, aydınlık-karanlık gibi ikili değişkenler, bulanık mantıkta biraz soğuk, biraz sıcak, biraz karanlık gibi esnek niteleyicilerle yumuşatılarak gerçek dünyaya benzetilir. En önemli fark, böyle bir çatıda bilginin kaynağındaki küme üyeliğinin kesin tanımlanmış önkoşullarının olmayışı ve daha çok problemlerle rasgele değişkenlerin hazır bulunmasındaki iş yapılan doğal yolu hazırlamasıdır.

Bulanık kümeler için Şekil 1.18'de bir örnek verilmiştir. Burada $10-40^{\circ}\text{C}$ arasındaki değerler sıcak kümesine üyedirler. $20-40^{\circ}\text{C}$ arasındaki değerler üyelik dereceleri 1'dir, $10-20^{\circ}\text{C}$ arasındaki sıcaklıkların ise üyelik dereceleri 0 ile 1 değerleri arasında değişecektir. Başka bir deyişle örneğin 11°C az sıcak, 15°C biraz sıcak olarak değerlendirilecektir. 20°C 'yi oda sıcaklığı kabul ederek, soğuk bulanık kümesi oluşturulduğunda Şekil 1.18 elde edilir.

1.5.3.1 Üstünlükler

Bulanık mantık kuramının insan düşünüş tarzına çok yakın olması en büyük üstünlüğünü oluşturmaktadır. Bilindiği gibi denetim işlemlerinin birçoğu dilsel niteleyicilerle yapılmaktadır.

Bulanık mantık yaklaşımı matematiksel modele ihtiyaç duymadığından, matematiksel modeli iyi tanımlanamamış, zamanla değişen ve doğrusal olmayan sistemler en başarılı uygulama alanlarıdır. Bulanık mantık yaklaşımında işaretlerin bir ön işlemeye tabi tutulmaları ve geniş bir alana yayılmış değerlerin az sayıda üyelik işlevlerine indirgenmeleri, uygulamaların daha hızlı bir şekilde sonuca ulaşmasını sağlar.

1.5.3.2 Sakıncalar

Bulanık mantık uygulamalarında mutlaka kuralların uzman deneyimlerine dayanarak tanımlanması gerekir. Üyelik işlevlerini ve bulanık mantık kurallarını tanımlamak her zaman kolay değildir.

Üyelik işlevlerinin değişkenlerinin belirlenmesinde kesin sonuç veren belirli bir yöntem ve öğrenme yeteneği yoktur. En uygun yöntem deneme-yanılma yöntemidir, bu da çok uzun zaman alabilir. Uzun testler yapmadan gerçekten ne kadar üyelik işlevi gerektiğini önceden kestirmek çok güçtür.

Sistemlerin kararlılık, gözlemlenebilirlik ve denetlenebilirlik analizlerinin yapılmasında ispatlanmış kesin bir yöntemin olmayışı bulanık mantığın temel sorunudur. Günümüzde bu sadece pahalı deneyimlerle mümkün olmaktadır.

Bulanık mantık yaklaşımında üyelik işlevlerinin değişkenleri sisteme özeldir, başka sistemlere uyarlanması çok zordur. Bunun yanı sıra en sık belirtilen dezavantajları ise üyelik işlevlerinin ayarlanmasının uzun zaman alması ve öğrenme yeteneği olmamasıdır (Elmas, 2007).

1.6 Genetik Algoritma ve Tarihçesi

Genetik algoritmalar (GA), doğadaki canlıların geçirdiği süreci örnek alır ve iyi nesillerin kendi yaşamlarını korurken, kötü nesillerin yok olması ilkesine dayanır. Matematiksel modellemenin yapılamadığı veya kesin çözümün olmadığı problemlerde genetik algorithmadan yararlanılır. Bu algoritma, anne ve baba bireyden (bir önceki nesil) doğan yeni bireylerin şartlara uyum sağlayıp yaşamlarını devam ettirmesine dayanır. Yeni bireyler, anne ve babasından gelen iyi genleri bünyelerinde muhafaza edebileceği gibi kötü genleri de almış olabilir. Bu durumda kötü genlere sahip bireyler varlıklarını sürdüremeyecektir.

Genetik algoritmalar, uygunluk işlevi, yeni çözümler üretmek için çaprazlama ve değiştirme gibi operatörleri kullanılır. Genetik algoritmanın önemli özelliklerinden birisi de bir grup üzerinde çözümü araması ve bu sayede çok sayıda çözümün içinden en iyiyi seçmesidir.

Goldberg'in tanımına göre GA, rastlantısal arama tekniklerini kullanarak çözüm bulmaya çalışan, parametre kodlama esasına dayanan sezgisel bir arama tekniğidir.

GA evrimsel yaklaşım ilkeleri ışığında rastlantısal araştırma yöntemlerini kullanarak kendi kendine öğrenme ve karar verme sistemlerinin düzenlenmesini hedef alan bir araştırma tekniğidir.

Biyolojik bir süreç içerisinde GA, doğal seçim ve genetik popülasyonların modellenmesi olarak John Holland tarafından 1975 yılında geliştirilmiştir. Holland evrimden ve canlılardaki bu süreçten yararlanarak, makine öğrenmesi üzerine çalışmalarını yoğunlaştırmıştır. Bu süreci bilgisayar ortamına taşıyarak tek bir mekanik yapının öğrenme yeteneğini geliştirmek yerine böyle yapılardan oluşan topluluğun çiftleşme, çoğalma ve değişim gibi genetik süreçlerden geçerek başarılı yeni bireyler oluşturabildiğini görmüştür.

Holland, çalışmalarında bir genetik bileşeni bir sistemin girişinde kullanılmak üzere bir makine öğrenme tekniğini geliştirmiştir. Daha sonraları ise GA'nın

doğrusal olmayan çok değişkenli eniyileme problemlerin çözümünde kullanılması ile önemli bir araştırma algoritması olduğu kanıtlanmıştır. GA'nın 1967 yılından itibaren günümüze gelen tarihsel gelişim sürecine bakıldığında Bagley 1967 yılındaki çalışmasında ilk defa genetik algoritmalarından bahsederken ancak öğrencisi Holland tarafından uygulanmaya başlanmıştır. Holland, genetik algoritmaların birleşimsel eniyileme problemlerinde etkin bir çözüm ürettiğini belirtmiştir. GA'nın kısıtlı optimizasyon problemleri kapsamına giren çizelgeleme yöntemlerinden biri olan atölye çizelgeleme problemlerinde etkili olarak ilk defa Davis tarafından 1985 yılında kullanılmıştır. 1987 yılında Liepis ise ilk defa genetik algoritma yapısını iki makineli çizelgelemeye uygulamıştır. Biegal ve Daven 1990 yılındaki çalışmalarında atölye çizelgelemede genetik algoritmayı bütünleşmiş imalat çevrimi içinde kullanmışlar ve bu yapıyı tek, iki ve çok makineli sistemlere uygulamışlardır. Nakano ise 1996'da genetik algoritmaların ikili kod sisteminde gösterimini atölye çizelgeleme probleminde kullanmıştır. Spears ve De Jong 1991 yılındaki çalışmalarında iki noktalı çaprazlama operatörünün her zaman bir noktalı çaprazlama operatöründen daha etkili olduğunu belirtmiştir. Chen ve arkadaşları genetik algoritmaların literatürdeki diğer sezgisel yaklaşımlardan daha iyi sonuç verdiğini 1995 yılında göstermişlerdir (Elmas, 2007).

1.6.1 Genetik Algoritmaların Uygulama Alanları

Temel ilkelerinin ortaya atılmasından sonra, genetik algoritmalar hakkında birçok bilimsel çalışma yayınlanmış ve GA'nın aşağıdaki alanlarda başarılı uygulamaları bulunmaktadır.

Eniyileme (Optimizasyon); GA araştırmalarının önemli bir bölümü fonksiyon eniyilemesi ile ilgilidir. GA, geleneksel eniyileme tekniklerine göre zor, süreksiz ve gürültü içeren fonksiyonları çözmede daha etkindirler. GA'nın uygulandığı diğer bir eniyileme problemi ise, istenen amaçlara ulaşmak üzere, sınırlı kaynakların etkin tahsis edilmesiyle ilgili birleşik eniyileme problemleridir. Gezgin satıcı problemi, araç yön bulma problemi, iş atölyesi çizelgeleme problemi, yerleşim tasarımı problemi, birleşim eniyileme problemlerine örnektir.

Otomatik Programlama ve Bilgi Sistemleri; GA'nın yaygın olarak kullanıldığı alanlardan biri, belirli ve özel görevler için gerekli olan bilgisayar programlarını geliştirmedir. Ayrıca, diğer hesaplama gerektiren yapıların tasarımı için de kullanılmaktadır. Bunlara örnek olarak bilgisayar çipleri tasarımı, ders programı hazırlanması ve ağların çizelgelenmesi verilebilir.

Mekanik Öğrenme; sınıflama sistemi GA'nın mekanik öğrenme alanında bir uygulamasıdır. Basit dizi kurallarını öğrenen bir mekanik öğrenme sistemi olan sınıflama sisteminin kural ve mesaj sistemi, özel bir üretim sistemi olarak adlandırılabilir. Bu üretim sistemi, “eğer-sonra” kural yapısını kullanır. Bir üretim kuralı, “eğer” yapısından sonra belirtilen durum için, “sonra” yapısından sonra gelen faaliyetin gerçekleştirilmesini içerir. GA, sınıflama sistemlerinde kural-bulma mekanizması olarak kullanılmaktadırlar. Ayrıca, sinir ağlarında ve proteinin yapısal analizinde de kullanılmaktadır.

Finans ve Pazarlama; GA finansal modelleme uygulamaları için son derece uygundur. Özellikle hisse senedi fiyatlarındaki değişim kalıplarını tahmin etmede ve bulmada, kaynak tahsisi ve uluslararası sermaye tahsisi stratejilerini belirlemede GA kullanılabilir. Pazarı ve tüketiciyi tanımda son derece önemli rol oynayan veri madenciliği, veriyi bilgiye bilgiyi de güvenli kararlara dönüştürür. Veri madenciliğinin verimlilik, karlılık, müşteri tatmini ve rekabet edebilme yeteneği gibi yaşamsal konularda işletme üzerinde çok önemli etkileri bulunmaktadır. Veri madenciliğinde kullanılan tekniklerden birisi de GA'dır. GA tabanlı yaklaşım kullanılarak veri yığınlarından modeller elde edilmektedir (Elmas, 2007).

BÖLÜM İKİ

MATERYAL VE YÖNTEM

2.1 Materyal

2.1.1 Kullanılan Boyarmadde, Kimyasal Maddeler ve Cihaz

2.1.1.1 Cihaz

Denemeler çektirme yöntemine göre TESA marka ELİAR TBB 100 otomatik programlı 20gr'lık laboratuvar tipi boyama makinesinde yapılmıştır.

2.1.1.2 Boyarmadde

Denemelerde Procion grubundan; Procion Yellow H-E4R, Procion Crimson H-EXL ve Procion Navy H-EXL boyarmaddeleri ile çalışılmıştır.

- **Procion Yellow H-E4R:** Dystar firmasına ait Azo-Reaktif boya.

Renk: Sarı

Suda çözünürlük: ≈ 70 g/l (20 °C)

pH: $\approx 7,0$ (10 g/l)

- **Procion Crimson H-EXL:** Dystar firmasına ait Azo-Reaktif boya.

Renk: kırmızı

Suda çözünürlük: 140 g/l (20 °C)

pH: 9,3 (10 g/l)

- **Procion Navy H-EXL:** Dystar firmasına ait Azo-Reaktif boya.

Renk: Mavi

Suda çözünürlük: 150 g/l (20 °C)

pH: 7,3 (20 °C, 10 g/l)

2.1.1.3 Kimyasal Maddeler

Denemelerde kullanılan kimyasal maddeler belirtildiği gibidir:

- **Dekol Sad:** BASF-Türk firmasına ait iyon tutucu.
- **Asetik Asit (CH_3COOH):** Ak-Kim firmasına ait %80'lik asetik asit.
- **Sodyum karbonat (Na_2CO_3):** Soda Sanayii firmasına ait sodyum karbonat (%99.1).
- **Sodyum Klorür (NaCl):** E.Güler Tuz firmasına ait sodyum klorür.

2.1.2 Kumaş

Denemelerde 30/1 penye süprem kumaş kullanılmıştır. Kumaş ham olarak temin edilmiş ve sırasıyla top açma→ kasar→ zincir kurutma→ sanfor→ kalite kontrol operasyonlarına tabi tutulmuştur.

2.2 Yöntem

(1) Kumaş, boyama ve koşullardaki standardizasyonu sağlayabilmek için düzgünlük ve tekrarlanabilirliği etkileyen birçok parametrenin (tuz miktarı, alkali miktarı, flotte oranı, boyama sıcaklığı, boyama süresi vb.) kontrol altına alınması gerekmektedir. Laboratuvar koşullarında bu parametrelerdeki sapmaların ne gibi sonuçlar ortaya çıkarabileceğini gözlemlemek amacıyla, laboratuvar ortamında denemeler yapılmıştır.


İki farklı renk için yapılan denemeler sonucunda her bir renk için referans boyama standart kabul edilerek, ΔE , ΔL^* , ΔC^* , ΔH^* gibi spektral değerler elde edilmiştir. Daha sonra bu değerlerin istatistiksel yöntemle analizi yapılmıştır.

(2) Laboratuvar koşullarında boyamalar sonucu elde edilen verileri yapay sinir ağları ile test edebilmek amacıyla farklı tekrar sayılarında farklı reçetelerle denemeler yapılmıştır. İlk olarak 50 farklı reçete, 10 defa tekrar edilerek 500 adet boyama yapılmıştır. Daha sonra reçete ve tekrar sayısının artmasıyla daha yaklaşık

sonuçların elde edilebileceği öngörülerek, 100 farklı reçete 20 defa tekrar edilerek 2000 adet boyama yapılmıştır.

Laboratuvarda yapılan 2000 adet boyamanın ardından, sistemde test edebilmek amacıyla 4 adet de işletme boyaması yapılmıştır. Bu boyamaların 2 tanesi, 100 reçetenin içerisinde seçilen konsantrasyon değerleri ile yapılmıştır. Diğer ikisi için ise ara konsantrasyon değerleri belirlenmiştir.

Boyanan kumaşların renk ölçümü yapılarak, CIELab ve reflektans değerleri tespit edilmiştir. Elde edilen bu değerler yapay sinir ağları ve bulanık mantık yöntemleri ile renk reçetesi tahmininde kullanılmıştır. Farklı metotlarla denemeler yapılmıştır. Her birinin göstermiş olduğu performans ve alınan sonuçlar değerlendirilmiştir.



Şekil 2.1 Deney planı

2.2.1 Laboratuvar Parametre Denemeleri

Laboratuvarda yapılan denemelerde; standart kumaş, standart boyarmadde ve standart boyama makinesi ile çalışılıyor olduğu göz önüne alınarak, kontrol edilecek olan parametreler,

- Tuz miktarı
- Alkali miktarı
- Flotte oranı
- Boyama sıcaklığı
- Boyama süresi olarak belirlenmiştir.

Tuz miktarı: Reaktif boyarmaddelerin substantifikleri genel olarak düşük olduğundan, çektirme yöntemindeki boyamalarda flotteye tuz ilave ederek boyarmaddenin substantifliği artırılmaktadır. Boyarmaddenin substantifliğine, boyama koyuluğuna, boyama sıcaklığına, flotte oranına bağlı olarak flotteye konulacak optimum tuz miktarı saptanmaktadır.

Alkali miktarı: Reaktifliği düşük olan boyarmaddelerde daha çok ve kuvvetli alkali kullanılmakla beraber, uygulanan boyama yöntemine göre alkali olarak kostik, soda, sodyum bikarbonat veya soda/ bikarbonat karışımı kullanılmaktadır. pH değerinin bir basamak artması, reaktif boyarmaddelerin reaksiyon hızının yaklaşık 10 kat artmasına yol açmaktadır. Dolayısıyla pH- değerindeki sapmalar, fiksajda da ani sıçramalara neden olacağı için düzgünsüz boyamalara yol açabilmektedir. Boyarmaddenin reaktifliğine, koyuluğuna ve boyama sıcaklığına göre (belirli flotte oranları için) kataloglarda önerilen alkali miktarları mevcuttur.

Flotte oranı: Artan flotte oranıyla beraber boyarmaddenin substantifliği ve boyarmadde verimi azalırken, migrasyonda artış gözlenmektedir. Diğer yandan flotte oranının artması boyarmaddenin su ile reaksiyona girmesini desteklemekte ve böylece hidroliz olan boyarmadde kısmı yükselmektedir. Bu nedenle gerek laboratuvar boyamalarında gerekse işletmede ve partiler arasındaki çalışmalarda

flottenin hazırlanmasına gerekli hassasiyetin gösterilerek aynı banyo oranlarında çalışılıp çalışılmadığı kontrol edilmelidir.

Boyama sıcaklığı: Optimal boyama sıcaklığının yükselmesiyle boyarmaddenin reaksiyon hızında, substantifliğinde ve veriminde farklılıklar ortaya çıkmaktadır. Sıcaklığın 10°C yükselmesi, reaksiyon hızını 2-3 kat artırmaktadır. Reaksiyon hızındaki artış ise boyarmaddenin su ile reaksiyonunu artırma gibi sakıncayı da beraberinde getirmektedir. Dolayısıyla boyama sıcaklığında olabilecek küçük farklılıklar sonucu tekrarlanabilir boyama eldesi zorlaşmış olacaktır.

Boyama süresi: Reaktif boyarmaddeler ile boyamada, boyarmaddenin fiksaj adımı tamamlandıktan sonra, boyama süresini uzatarak flottede kalan boyarmaddenin bir miktarını daha aldirmaya çalışmanın önemli bir faydası genellikle yoktur.

2.2.1.1 Boyama Reçetesi

Laboratuvar denemelerinde iki farklı reçete olarak, kahverengi ve pembe renkleri veren reçeteler seçilmiştir. Kahverengi, laboratuvar koşullarında düzgünlük ve tekrarlanabilirlik yönünden bakıldığında zor bir renktir. Pembe ise tutturulması daha kolay bir renktir. Denemelerde, kıyaslama olanağı açısından bu iki renk seçilmiştir.

Kahverengi boyanan kumaş için;


Procion Yellow H-E4R	% 0,80
Procion Crimson H-EXL	% 0,35
Procion Navy H-EXL	% 0,40
pH 5.5-6 (Asetik asit)	1,8ml
İyon Tutucu (Dekol Sad)	0,8ml
Soda	6ml
Tuz (NaCl)	21ml
Flotte oranı	1:8

Pembe boyanan kumaş için;

Procion Yellow H-E4R	% 0,25
Procion Crimson H-EXL	% 1.10
Procion Navy H-EXL	% 0,20
pH 5.5-6 (Asetik asit)	1,8ml
İyon Tutucu (Dekol Sad)	0,8ml
Soda	6ml
Tuz (NaCl)	21ml
Flotte oranı	1:8

Reçetede soda ve tuz miktarları, her bir reçete için boya yüzdeleri toplamına bakılarak kataloglardan belirlenmiştir. Asetik asit miktarı, boya yüzdesi %1 ve altı olanlarda 2,5ml, %1'in üzerinde olan reçetelerde ise 1,8ml olarak belirlenmiştir. (Her bir boyamada kullanılan kumaş ağırlığı 10 gr'dır.)

2.2.1.2 Boyama Grafiği



Şekil 2.2 Boyama grafiği

2.2.1.3 Yıkama İşlemi

Boyama işleminin ardından kumaşlar yıkama işlemine tabi tutulmuştur. Yıkama işlemi;

- Soğuk durulama (5 dak.)
- 95°C’da yıkama (10 dak.)
- 95°C’da yıkama (10 dak.)
- Asitleme (pH 5.5)
- Soğuk durulama şeklindedir.

Kumaşlar, yıkama işlemlerinden sonra etüvde kurutulmuş ve 30 dakika süre ile kondüsyonlanmıştır.

2.2.1.4 Renk Ölçümü

Boyanan kumaşların renk ölçümü Data Colour (SF 600X) marka renk ölçüm cihazında, CIELab sistemine göre, D65 ışık kaynağı altında, 10° gözlem açısı ile yapılmıştır. L^* , a^* , b^* , C^* , h ve tristimulus (X,Y,Z) değerleri kaydedilmiştir. Kumaşların % R değerleri 4 farklı yerinden ölçüm alınarak ortalama değerleri okunmuştur. Kumaşların 400-700 nm aralığındaki remisyon değerleri alınmıştır (10 nm aralıklarla).

Laboratuvar parametre denemelerinde ise **referans boyama standart kabul edilerek**; ΔE , ΔL^* , ΔC^* , ΔH^* gibi spektral değerler elde edilmiştir. Bu değerler ölçülen numuneler ile referans numune sonuçlarının birbirlerine olan farkları ile hesaplanmaktadır. ΔE ise toplam renk farkını temsil etmektedir.

$$\Delta E = [(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2]^{1/2}$$

(Toplam renk farkı)

$$\Delta L^* = (L^*_{\text{numune}} - L^*_{\text{standart}})$$

(Açıklık-koyuluk renk farkı)

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

(Doygunluk farkı)

$$\Delta H^* = (h^*_{\text{numune}} - h^*_{\text{standart}})$$

(Açısal renk farkı)

2.2.2 Yapay Sinir Ağları ile Reçete Tahmini

Renk reçete tahminlemesi; verilen bir referans renk ile aynı rengi üretmek için hangi boyarmaddelerin hangi konsantrasyonlarına ihtiyaç duyulduğunu tahmin etmektir. İyi bir tahminleme yapabilmek deneyimli boya uzmanları için bile zordur. Reçete tahmini; klasik reçete çıkarma sistemine göre veya bilgisayarlı reçete çıkarma sistemine göre yapılabilir. Klasik reçete çıkarma sisteminde bir boya uzmanı deneyimlerine dayanarak verilen renge yakın bir reçete tutturmaya çalışır, bilgisayarlı reçete çıkarma sistemleri ise yaygın olarak bilinen doğrusal modele (Kubelka-Munk modeli) veya doğrusal olmayan (sinir ağları, bulanık mantık) modele dayanabilir.

Doğrusal olmayan modeller olarak yapay sinir ağları (ANN) ve bulanık mantık (Fuzzy Logic), bu tez çalışmasında, renk reçetesi tahmininde kullanılan yöntemlerdir. Yapay sinir ağlarında, Multi Layer Perceptron (MLP) ve Radial Basis Function (RBF) metotları; bulanık mantıkta ise Adaptive Neuro-Fuzzy Inference System (ANFIS) metodu kullanılmıştır. Bu uygulamalar MATLAB platformunda yapılmıştır. Uygulamalar için gerekli olan veriler ise boyamalar sonucu elde edilmiştir. Renk ölçümü sonucunda elde edilen CIELab ve reflektans değerleri, girdi değerleri olarak; konsantrasyon değerleri ise çıktı değerleri olarak kullanılmıştır.

2.2.2.1 Uygulama (1)

Boyamalar sonucu elde edilen verileri bulanık mantık ve yapay sinir ağları ile test edebilmek amacıyla farklı tekrar sayılarında farklı reçetelerle denemeler yapılmıştır. Uygulamanın ilk aşamasında 50 farklı reçete, 10 defa tekrar edilerek 500 adet boyama yapılmıştır. Boyamaların 250 tanesi eğitim seti olarak kullanılmıştır. Test setinde ise 500 boyamaya ait verilerin tamamı kullanılmıştır.

Aşağıdaki tablolarda 50 farklı reçeteye ait konsantrasyon değerleri, herhangi bir tekrara ait CIELab değerleri ve 400-700 nm arasındaki reflektans değerleri verilmiştir.

Tablo 2.1 50 farklı reçeteye ait 400-500 nm arasındaki reflektans değerleri

	400	410	420	430	440	450	460	470	480	490	500
1	16,00	15,64	15,26	15,07	15,07	15,20	15,37	15,39	15,09	14,71	14,36
2	17,53	17,26	16,89	16,75	16,71	16,79	16,89	16,83	16,40	15,93	15,50
3	13,08	12,89	12,62	12,53	12,50	12,54	12,58	12,43	12,04	11,56	11,14
4	11,88	11,75	11,53	11,47	11,46	11,50	11,52	11,36	10,95	10,48	10,06
5	14,84	14,67	14,39	14,35	14,35	14,34	14,24	13,66	12,65	11,78	10,91
6	13,53	13,51	13,40	13,38	13,39	13,37	12,95	12,01	10,68	9,63	8,64
7	12,52	12,55	12,53	12,52	12,53	12,36	11,86	10,72	9,27	8,15	7,15
8	12,14	11,66	11,16	10,97	10,96	11,14	11,52	11,86	12,17	12,44	12,68
9	8,90	8,44	8,01	7,86	7,85	8,03	8,44	8,88	9,41	9,92	10,60
10	7,47	7,06	6,63	6,52	6,50	6,68	7,08	7,55	8,17	8,78	9,66
11	10,91	10,62	10,28	10,23	10,25	10,39	10,56	10,56	10,35	10,07	9,79
12	10,21	9,91	9,63	9,56	9,57	9,69	9,82	9,81	9,58	9,27	8,97
13	9,28	9,05	8,83	8,75	8,77	8,88	8,97	8,94	8,66	8,32	8,00
14	8,72	8,54	8,30	8,23	8,23	8,30	8,36	8,31	8,02	7,66	7,36
15	10,91	10,54	10,18	10,05	10,06	10,24	10,57	10,84	11,03	11,15	11,23
16	9,36	9,16	9,00	8,90	8,93	8,99	8,98	8,74	8,21	7,70	7,21
17	8,84	8,71	8,55	8,50	8,51	8,52	8,36	7,98	7,28	6,67	6,09
18	13,53	13,42	13,25	13,23	13,22	13,21	13,09	12,52	11,55	10,72	9,93
19	7,74	7,44	7,13	7,06	7,07	7,21	7,44	7,61	7,70	7,71	7,69
20	6,54	6,27	6,03	5,93	5,96	6,11	6,37	6,62	6,85	7,04	7,18
21	8,01	7,70	7,36	7,22	7,21	7,30	7,42	7,43	7,30	7,12	6,91
22	7,69	7,44	7,16	7,07	7,07	7,16	7,26	7,24	7,10	6,87	6,65
23	7,19	6,90	6,68	6,58	6,57	6,65	6,74	6,73	6,57	6,34	6,12
24	6,83	6,61	6,39	6,29	6,27	6,33	6,39	6,35	6,18	5,94	5,72
25	7,97	7,60	7,20	7,08	7,06	7,19	7,46	7,75	8,04	8,33	8,62
26	7,48	7,17	6,86	6,76	6,73	6,80	6,88	6,88	6,74	6,56	6,36
27	6,92	6,72	6,49	6,41	6,40	6,44	6,43	6,29	5,97	5,62	5,30
28	11,04	11,00	10,89	10,84	10,80	10,75	10,43	9,75	8,71	7,87	7,10
29	8,73	8,56	8,38	8,30	8,28	8,31	8,29	8,06	7,57	7,10	6,65
30	6,39	6,16	5,93	5,82	5,81	5,90	6,03	6,10	6,06	5,97	5,87
31	6,42	6,16	5,99	5,89	5,87	5,93	6,03	6,04	5,93	5,76	5,59
32	6,08	5,84	5,66	5,58	5,54	5,60	5,69	5,69	5,57	5,40	5,24
33	5,74	5,55	5,37	5,30	5,28	5,33	5,40	5,39	5,28	5,11	4,95
34	5,71	5,54	5,42	5,34	5,32	5,38	5,45	5,44	5,30	5,11	4,93
35	6,26	5,96	5,70	5,61	5,57	5,68	5,94	6,23	6,55	6,86	7,23
36	6,05	5,78	5,59	5,51	5,47	5,56	5,75	5,91	6,03	6,11	6,18
37	5,86	5,66	5,52	5,44	5,42	5,50	5,62	5,68	5,63	5,53	5,43
38	9,12	9,16	9,18	9,15	9,10	9,00	8,67	7,94	6,96	6,17	5,49
39	7,52	7,41	7,34	7,28	7,25	7,22	7,10	6,78	6,20	5,69	5,22
40	6,56	6,40	6,31	6,23	6,21	6,23	6,23	6,12	5,80	5,45	5,14
41	5,27	5,07	4,94	4,89	4,88	4,94	5,01	5,00	4,88	4,71	4,55
42	5,04	4,85	4,73	4,68	4,67	4,72	4,79	4,79	4,67	4,50	4,34
43	5,00	4,83	4,71	4,66	4,65	4,71	4,77	4,75	4,62	4,43	4,26
44	4,63	4,55	4,45	4,40	4,38	4,42	4,47	4,46	4,33	4,15	3,99
45	4,77	4,66	4,59	4,54	4,51	4,55	4,58	4,55	4,41	4,22	4,05
46	5,20	4,98	4,79	4,70	4,67	4,77	5,01	5,28	5,59	5,91	6,29
47	5,15	4,93	4,75	4,68	4,67	4,75	4,92	5,09	5,24	5,36	5,47
48	4,81	4,64	4,53	4,48	4,48	4,56	4,70	4,81	4,85	4,84	4,81
49	4,56	4,41	4,33	4,30	4,27	4,32	4,40	4,43	4,37	4,27	4,17
50	4,07	3,96	3,90	3,88	3,88	3,92	3,94	3,89	3,75	3,57	3,41

Tablo 2.1 (devam) 50 farklı reçeteye ait 510-600 nm arasındaki reflektans değerleri

	510	520	530	540	550	560	570	580	590	600
1	13,73	13,15	12,91	12,68	12,08	12,15	12,99	14,95	16,61	17,34
2	14,81	14,08	13,57	13,02	12,16	11,74	12,09	12,84	13,30	13,42
3	10,54	9,91	9,41	8,88	8,15	7,75	7,87	8,08	8,23	8,24
4	9,51	8,87	8,33	7,77	7,06	6,63	6,59	6,64	6,66	6,60
5	9,89	9,14	8,91	8,71	8,47	8,49	9,78	12,45	15,28	17,01
6	7,57	6,88	6,70	6,59	6,41	6,51	7,81	10,70	14,19	16,58
7	6,16	5,60	5,39	5,30	5,21	5,32	6,56	9,55	13,69	17,06
8	12,79	12,85	12,91	12,88	12,46	12,57	13,56	15,66	17,44	18,26
9	11,14	11,53	11,93	12,00	11,84	11,81	12,87	14,84	16,49	17,24
10	10,48	11,17	11,85	12,06	12,03	12,08	13,16	15,16	16,86	17,66
11	9,24	8,86	8,74	8,65	8,48	8,57	9,93	12,67	15,52	17,24
12	8,49	8,08	7,87	7,66	7,36	7,36	8,02	9,49	10,77	11,34
13	7,53	7,13	6,84	6,60	6,22	6,16	6,50	7,35	7,97	8,26
14	6,91	6,52	6,20	5,93	5,52	5,40	5,59	6,07	6,37	6,54
15	11,15	11,02	10,80	10,49	9,90	9,68	10,03	10,80	11,29	11,44
16	6,57	6,13	5,94	5,81	5,62	5,62	6,45	8,18	9,97	11,03
17	5,43	5,03	4,86	4,76	4,64	4,67	5,49	7,28	9,36	10,70
18	8,97	8,25	7,94	7,70	7,28	7,31	7,96	9,45	10,77	11,34
19	7,54	7,41	7,30	7,22	6,93	6,90	7,64	9,08	10,37	10,94
20	7,23	7,26	7,27	7,22	7,04	7,00	7,76	9,22	10,53	11,13
21	6,57	6,39	6,31	6,29	6,24	6,34	7,49	10,08	13,40	15,91
22	6,28	6,04	5,91	5,81	5,66	5,67	6,47	8,13	9,87	10,90
23	5,78	5,53	5,36	5,23	5,03	5,04	5,46	6,49	7,50	8,01
24	5,39	5,16	4,96	4,82	4,56	4,52	4,80	5,53	6,14	6,45
25	8,85	8,93	8,85	8,64	8,06	7,73	7,85	8,09	8,25	8,28
26	6,04	5,84	5,73	5,65	5,50	5,50	6,29	7,94	9,67	10,65
27	4,87	4,61	4,45	4,36	4,22	4,27	4,75	5,93	7,19	7,91
28	6,28	5,69	5,42	5,20	4,96	4,94	5,36	6,40	7,42	7,91
29	6,08	5,67	5,44	5,28	5,03	5,05	5,49	6,54	7,56	8,04
30	5,65	5,50	5,38	5,28	5,10	5,12	5,58	6,66	7,70	8,21
31	5,30	5,15	5,11	5,11	5,10	5,24	6,41	9,17	12,95	15,97
32	4,95	4,79	4,70	4,66	4,59	4,64	5,42	7,12	9,17	10,59
33	4,69	4,52	4,40	4,33	4,22	4,28	4,74	5,88	7,11	7,87
34	4,65	4,46	4,30	4,20	4,06	4,07	4,43	5,27	6,12	6,53
35	7,53	7,66	7,60	7,39	6,89	6,53	6,51	6,55	6,59	6,55
36	6,15	6,08	5,95	5,79	5,48	5,37	5,55	6,02	6,33	6,51
37	5,22	5,06	4,89	4,77	4,57	4,53	4,82	5,54	6,13	6,46
38	4,80	4,35	4,10	3,94	3,76	3,75	4,07	4,86	5,66	6,04
39	4,70	4,32	4,12	3,99	3,82	3,82	4,15	4,97	5,78	6,18
40	4,74	4,45	4,27	4,15	3,99	3,99	4,35	5,19	6,02	6,42
41	4,28	4,14	4,10	4,11	4,12	4,23	5,22	7,68	11,43	14,83
42	4,10	3,96	3,89	3,88	3,84	3,89	4,60	6,25	8,41	10,04
43	4,00	3,85	3,75	3,71	3,65	3,71	4,21	5,42	6,84	7,79
44	3,76	3,61	3,50	3,44	3,36	3,39	3,74	4,59	5,53	6,07
45	3,81	3,64	3,52	3,44	3,34	3,34	3,62	4,32	5,04	5,40
46	6,64	6,78	6,74	6,56	6,08	5,75	5,63	5,60	5,57	5,51
47	5,51	5,47	5,36	5,20	4,89	4,75	4,85	5,11	5,30	5,40
48	4,70	4,58	4,44	4,33	4,13	4,07	4,28	4,74	5,09	5,31
49	3,99	3,85	3,73	3,64	3,50	3,48	3,78	4,31	4,81	5,09
50	3,18	3,04	2,93	2,88	2,79	2,80	3,11	3,60	4,16	4,49

Tablo 2.1 (devam) 50 farklı reçeteye ait 610-700 nm arasındaki reflektans değerleri

	610	620	630	640	650	660	670	680	690	700
1	17,55	17,75	18,06	19,19	21,56	25,49	31,19	39,03	46,01	55,34
2	13,40	13,45	13,67	14,65	16,73	20,31	25,64	33,13	39,94	49,30
3	8,18	8,22	8,40	9,09	10,70	13,67	18,41	25,45	32,04	41,18
4	6,52	6,54	6,70	7,27	8,63	11,20	15,42	21,99	28,29	37,18
5	17,76	18,11	18,53	19,70	22,14	26,14	31,92	39,78	46,71	55,89
6	17,75	18,21	18,70	19,91	22,41	26,51	32,41	40,46	47,46	56,64
7	18,93	19,69	20,30	21,59	24,13	28,27	34,19	42,20	49,13	58,18
8	18,49	18,70	19,02	20,19	22,63	26,71	32,61	40,64	47,61	56,83
9	17,46	17,67	17,99	19,11	21,49	25,45	31,19	39,09	46,06	55,36
10	17,90	18,12	18,45	19,60	22,00	25,96	31,73	39,60	46,47	55,59
11	17,96	18,32	18,74	19,92	22,37	26,37	32,16	40,03	46,87	55,92
12	11,55	11,72	11,98	12,90	14,87	18,32	23,55	30,97	37,67	46,79
13	8,36	8,46	8,75	9,40	11,03	13,96	18,59	25,46	31,84	40,67
14	6,57	6,63	6,80	7,39	8,75	11,31	15,51	22,00	28,22	36,98
15	11,45	11,51	11,77	12,63	14,59	17,99	23,17	30,54	37,23	46,36
16	11,46	11,70	12,02	12,95	14,93	18,38	23,61	30,98	37,62	46,62
17	11,29	11,60	11,96	12,87	14,85	18,30	23,56	31,02	37,72	46,84
18	11,56	11,74	12,00	12,92	14,92	18,40	23,69	31,18	37,93	47,13
19	11,16	11,33	11,62	12,49	14,43	17,82	23,01	30,42	37,12	46,23
20	11,36	11,54	11,81	12,73	14,67	18,06	23,21	30,55	37,16	46,21
21	17,27	17,83	18,36	19,54	21,93	25,85	31,54	39,34	46,15	55,17
22	11,33	11,60	11,95	12,85	14,84	18,26	23,37	30,61	37,16	46,16
23	8,23	8,40	8,75	9,39	11,00	13,89	18,43	25,14	31,42	40,18
24	6,58	6,69	6,87	7,47	8,87	11,47	15,72	22,21	28,44	37,21
25	8,24	8,28	8,47	9,16	10,78	13,78	18,55	25,63	32,23	41,37
26	11,01	11,28	11,56	12,48	14,46	17,93	23,21	30,70	37,48	46,70
27	8,16	8,37	8,71	9,35	10,99	13,94	18,61	25,51	31,95	40,92
28	8,13	8,28	8,62	9,25	10,88	13,82	18,49	25,44	31,91	40,90
29	8,25	8,41	8,75	9,38	11,03	13,95	18,58	25,43	31,81	40,64
30	8,43	8,60	8,94	9,59	11,22	14,14	18,78	25,59	31,92	40,67
31	17,64	18,34	18,91	20,15	22,59	26,69	32,52	40,44	47,24	56,26
32	11,27	11,61	11,96	12,91	14,89	18,35	23,58	31,00	37,61	46,71
33	8,16	8,40	8,75	9,40	10,99	13,92	18,51	25,34	31,68	40,53
34	6,75	6,91	7,21	7,77	9,18	11,79	16,02	22,49	28,64	37,28
35	6,50	6,55	6,71	7,29	8,63	11,19	15,39	21,86	28,05	36,82
36	6,56	6,64	6,81	7,39	8,73	11,30	15,47	21,91	28,08	36,81
37	6,60	6,73	6,92	7,52	8,89	11,46	15,62	22,02	28,12	36,74
38	6,25	6,39	6,58	7,15	8,47	10,99	15,14	21,61	27,84	36,66
39	6,39	6,54	6,73	7,31	8,64	11,18	15,31	21,73	27,88	36,63
40	6,64	6,79	7,01	7,61	8,98	11,58	15,78	22,23	28,40	37,09
41	16,94	17,85	18,54	19,81	22,23	26,24	31,94	39,72	46,42	55,33
42	10,91	11,30	11,68	12,62	14,54	17,90	22,95	30,15	36,62	45,55
43	8,22	8,48	8,84	9,53	11,17	14,10	18,69	25,50	31,78	40,54
44	6,34	6,53	6,78	7,34	8,66	11,13	15,15	21,39	27,38	35,90
45	5,59	5,72	5,90	6,43	7,65	9,98	13,88	20,04	26,06	34,64
46	5,46	5,49	5,62	6,11	7,26	9,51	13,29	19,33	25,31	33,89
47	5,42	5,48	5,62	6,10	7,24	9,46	13,19	19,16	25,07	33,59
48	5,40	5,49	5,65	6,14	7,27	9,41	13,01	18,78	24,50	32,79
49	5,21	5,31	5,46	5,95	7,07	9,27	12,99	18,98	24,91	33,42
50	4,66	4,77	4,92	5,36	6,33	8,30	11,68	17,23	22,88	31,14

Tablo 2.2 50 farklı reçeteye ait CIELab ve Tristimulus (X,Y,Z) değerleri

	L*	a*	b*	c*	h	x	y	z
1	44,85	8,77	-1,73	8,94	348,86	15,11	14,44	16,27
2	43,76	2,75	-7,08	7,60	291,21	13,38	13,67	17,91
3	36,37	1,24	-9,45	9,53	277,47	8,87	9,20	13,31
4	33,85	-0,06	-10,86	10,86	269,67	7,52	7,94	12,17
5	40,88	17,65	-5,54	18,49	342,58	13,77	11,79	14,91
6	38,10	23,31	-7,05	24,35	343,18	12,80	10,15	13,55
7	36,62	28,33	-6,71	29,12	346,68	12,60	9,33	12,41
8	44,73	8,41	7,62	11,35	42,17	14,96	14,35	12,27
9	42,98	8,09	13,97	16,14	59,91	13,69	13,15	9,05
10	42,90	8,55	18,64	20,50	65,37	13,71	13,09	7,64
11	40,34	16,34	3,23	16,66	11,19	13,20	11,45	11,10
12	36,20	9,47	-1,69	9,62	349,89	9,78	9,11	10,34
13	32,86	6,27	-4,69	7,83	323,19	7,74	7,47	9,43
14	30,60	4,11	-6,59	7,76	301,92	6,53	6,48	8,81
15	39,37	2,33	1,28	2,65	28,79	10,61	10,87	11,21
16	33,48	14,78	-3,53	15,20	346,56	8,99	7,76	9,40
17	31,64	18,13	-4,66	18,72	345,57	8,47	6,93	8,77
18	36,82	11,51	-9,65	15,02	320,03	10,38	9,44	13,70
19	34,86	9,07	4,00	9,91	23,80	9,02	8,43	7,86
20	34,72	8,97	7,89	11,94	41,35	8,94	8,36	6,75
21	36,47	20,76	6,87	21,87	18,30	11,42	9,25	7,83
22	33,02	13,62	1,60	13,71	6,69	8,63	7,55	7,65
23	30,20	9,48	-1,25	9,56	352,47	6,89	6,32	7,10
24	28,27	7,11	-3,19	7,80	335,81	5,88	5,56	6,75
25	34,81	-0,47	3,49	3,52	97,60	7,92	8,40	7,98
26	32,53	13,59	2,09	13,75	8,74	8,39	7,32	7,28
27	28,65	12,74	-2,65	13,02	348,26	6,55	5,70	6,77
28	30,96	12,37	-12,51	17,59	314,69	7,52	6,64	10,96
29	30,69	10,48	-6,08	12,11	329,87	7,20	6,52	8,70
30	30,22	9,32	1,65	9,47	10,01	6,88	6,33	6,38
31	34,76	24,43	9,52	26,21	21,29	10,92	8,38	6,37
32	30,81	16,77	4,20	17,29	14,07	7,91	6,57	6,00
33	28,30	12,08	1,18	12,14	5,58	6,35	5,57	5,70
34	27,11	9,35	-1,06	9,41	353,52	5,64	5,13	5,75
35	31,75	-2,07	4,29	4,76	115,78	6,42	6,98	6,38
36	29,61	2,89	1,67	3,34	30,07	6,02	6,08	6,11
37	28,01	6,65	-0,31	6,66	357,32	5,74	5,46	5,93
38	27,08	12,53	-13,59	18,49	312,68	5,91	5,12	9,10
39	26,88	10,94	-8,33	13,76	322,71	5,69	5,05	7,47
40	27,16	9,92	-4,40	10,85	336,06	5,71	5,15	6,57
41	32,57	26,71	10,49	28,70	21,43	9,98	7,34	5,27
42	28,96	18,74	5,32	19,48	15,85	7,28	5,82	5,05
43	27,00	14,38	2,10	14,53	8,31	6,04	5,09	5,02
44	24,99	11,07	0,10	11,07	0,53	5,02	4,41	4,71
45	24,42	9,20	-1,48	9,32	350,86	4,68	4,23	4,84
46	29,55	-3,03	4,77	5,65	122,39	5,48	6,05	5,38
47	27,54	1,30	1,95	2,34	56,40	5,12	5,29	5,24
48	26,00	4,40	0,62	4,45	7,98	4,84	4,75	4,97
49	24,45	6,91	-0,50	6,93	355,88	4,52	4,24	4,65
50	22,11	8,77	-1,89	8,97	347,81	3,93	3,55	4,14

Tablo 2.3 50 farklı reçeteye ait konsantrasyon değerleri

	Procion Crimson H-EXL	Procion Navy H-EXL	Procion Yellow H-E4R
1	0,25	0,25	0,25
2	0,25	0,50	0,25
3	0,25	0,75	0,25
4	0,25	1,00	0,25
5	0,50	0,25	0,25
6	0,75	0,25	0,25
7	1,00	0,25	0,25
8	0,25	0,25	0,50
9	0,25	0,25	0,75
10	0,25	0,25	1,00
11	0,50	0,50	0,50
12	0,50	0,25	0,50
13	0,50	0,75	0,50
14	0,50	1,00	0,50
15	0,25	0,50	0,50
16	0,75	0,50	0,50
17	1,00	0,50	0,50
18	0,50	0,50	0,25
19	0,50	0,50	0,75
20	0,50	0,50	1,00
21	0,75	0,75	0,75
22	0,75	0,25	0,75
23	0,75	0,50	0,75
24	0,75	1,00	0,75
25	0,25	0,75	0,75
26	0,50	0,75	0,75
27	1,00	0,75	0,75
28	0,75	0,75	0,25
29	0,75	0,75	0,50
30	0,75	0,75	1,00
31	1,00	1,00	1,00
32	1,00	0,25	1,00
33	1,00	0,50	1,00
34	1,00	0,75	1,00
35	0,25	1,00	1,00
36	0,50	1,00	1,00
37	0,75	1,00	1,00
38	1,00	1,00	0,25
39	1,00	1,00	0,50
40	1,00	1,00	0,75
41	1,25	1,25	1,25
42	1,25	0,25	1,25
43	1,25	0,50	1,25
44	1,25	0,75	1,25
45	1,25	1,00	1,25
46	0,25	1,25	1,25
47	0,50	1,25	1,25
48	0,75	1,25	1,25
49	1,00	1,25	1,25
50	1,50	1,50	1,50

2.2.2.2 Uygulama (2)

Uygulamanın ikinci aşamasında, reçete ve tekrar sayısının artmasıyla daha yaklaşık sonuçların elde edilebileceği görülerek, 100 farklı reçete 20 defa tekrar edilerek 2000 adet boyama yapılmıştır. Boyamaların 1500 tanesi eğitim seti olarak kullanılmıştır. Test setinde ise 2000 boyamaya ait verilerin tamamı kullanılmıştır. Tablo 2.5'te 100 farklı reçeteye ait konsantrasyon değerleri verilmiştir.

Laboratuvarda yapılan 2000 adet boyamanın ardından, sistemde test edebilmek amacıyla 4 adet de işletme boyaması yapılmıştır. Bu boyamaların 2 tanesi, 100 reçetenin içerisinde seçilen konsantrasyon değerleri ile yapılmıştır. Diğer ikisi için ise ara konsantrasyon değerleri belirlenmiştir. Tablo 2.4'te işletme reçetelerine ait konsantrasyon değerleri verilmiştir.

Laboratuvar-işletme uyumu açısından, boyama yöntemleri, yıkama koşulları ve değerlendirme işlemleri, laboratuvar boyamaları ile aynı şekilde yapılmıştır. 20'şer kg'lık 4 adet kumaş, işletmede numune tipi overflow boyama makinelerinde boyanmıştır. Boyama ve yıkama işlemlerinin ardından, kumaşların spektrofotometrede renk ölçümleri yapılarak, CIELab ve reflektans değerleri elde edilmiştir.

Tablo 2.4 İşletme reçetelerine ait konsantrasyon değerleri

	Procion Crimson H-EXL	Procion Navy H-EXL	Procion Yellow H-E4R
1	0,40	0,80	0,80
2	1,00	0,40	1,00
3	0,22	0,55	0,22
4	1,10	1,10	0,11

Tablo 2.5 100 farklı reçeteye ait konsantrasyon değerleri

	Procion Crimson H-EXL	Procion Navy H-EXL	Procion Yellow H-E4R
1	0,10	0,10	0,10
2	0,10	0,10	0,20
3	0,10	0,10	0,30
4	0,10	0,10	0,40
5	0,10	0,10	0,50
6	0,10	0,20	0,10
7	0,10	0,30	0,10
8	0,10	0,40	0,10
9	0,10	0,50	0,10
10	0,20	0,10	0,10
11	0,30	0,10	0,10
12	0,40	0,10	0,10
13	0,50	0,10	0,10
14	0,20	0,20	0,10
15	0,20	0,20	0,20
16	0,20	0,20	0,30
17	0,20	0,20	0,40
18	0,20	0,20	0,50
19	0,20	0,10	0,20
20	0,20	0,30	0,20
21	0,20	0,40	0,20
22	0,20	0,50	0,20
23	0,10	0,20	0,20
24	0,30	0,20	0,20
25	0,40	0,20	0,20
26	0,50	0,20	0,20
27	0,50	0,50	0,10
28	0,50	0,50	0,20
29	0,50	0,50	0,30
30	0,50	0,50	0,40
31	0,50	0,50	0,50
32	0,50	0,50	0,60
33	0,50	0,50	0,70
34	0,50	0,50	0,80
35	0,50	0,10	0,50
36	0,50	0,20	0,50
37	0,50	0,30	0,50
38	0,50	0,40	0,50
39	0,50	0,60	0,50
40	0,50	0,70	0,50
41	0,50	0,80	0,50
42	0,10	0,50	0,50
43	0,20	0,50	0,50
44	0,30	0,50	0,50
45	0,40	0,50	0,50
46	0,60	0,50	0,50
47	0,70	0,50	0,50
48	0,80	0,50	0,50
49	0,90	0,50	0,50
50	1,00	0,50	0,50

Tablo 2.5 (devam) 100 farklı reçeteye ait konsantrasyon değerleri

	Procion Crimson H-EXL	Procion Navy H-EXL	Procion Yellow H-E4R
51	0,80	0,80	0,40
52	0,80	0,80	0,50
53	0,80	0,80	0,60
54	0,80	0,80	0,70
55	0,80	0,80	0,80
56	0,80	0,40	0,80
57	0,80	0,50	0,80
58	0,80	0,60	0,80
59	0,80	0,70	0,80
60	0,40	0,80	0,80
61	0,50	0,80	0,80
62	0,60	0,80	0,80
63	0,70	0,80	0,80
64	1,00	1,00	0,40
65	1,00	1,00	0,50
66	1,00	1,00	0,60
67	1,00	1,00	0,70
68	1,00	1,00	0,80
69	1,00	1,00	0,90
70	1,00	1,00	1,00
71	1,00	0,40	1,00
72	1,00	0,50	1,00
73	1,00	0,60	1,00
74	1,00	0,70	1,00
75	1,00	0,80	1,00
76	1,00	0,90	1,00
77	0,40	1,00	1,00
78	0,50	1,00	1,00
79	0,60	1,00	1,00
80	0,70	1,00	1,00
81	0,80	1,00	1,00
82	0,90	1,00	1,00
83	1,20	1,20	0,10
84	1,20	1,20	0,20
85	1,20	1,20	0,30
86	1,20	1,20	0,40
87	1,20	1,20	0,50
88	1,20	1,20	0,60
89	1,20	0,10	1,20
90	1,20	0,20	1,20
91	1,20	0,30	1,20
92	1,20	0,40	1,20
93	1,20	0,50	1,20
94	1,20	0,60	1,20
95	0,10	1,20	1,20
96	0,20	1,20	1,20
97	0,30	1,20	1,20
98	0,40	1,20	1,20
99	0,50	1,20	1,20
100	0,60	1,20	1,20

BÖLÜM ÜÇ

ARAŞTIRMA SONUÇLARI VE TARTIŞMA

3.1 Laboratuvar Boyama Parametrelerindeki Değişimlerin İncelenmesi

Kumaş, boyama ve koşullardaki standardizasyonu sağlayabilmek için düzgünlük ve tekrarlanabilirliği etkileyen birçok parametrenin (tuz miktarı, alkali miktarı, flotte oranı, boyama sıcaklığı, boyama süresi vb.) kontrol altına alınması gerekmektedir. Laboratuvar koşullarında bu parametrelerdeki sapmaların ne gibi sonuçlar ortaya çıkarabileceğini gözlemlemek amacıyla, laboratuvar ortamında denemeler yapılmıştır.

İki farklı renk için yapılan denemeler sonucunda her bir renk için referans boyama standart kabul edilerek, ΔE , ΔL^* , ΔC^* , ΔH^* gibi spektral değerler elde edilmiştir. Daha sonra bu değerlerin istatistiksel yöntemle analizi yapılmıştır.

3.1.1 Tuz Miktarı

Kahverengi ve pembe boyamalar (%1,55'lik) için, boyama kataloğunda laboratuvar koşulları için belirlenmiş olan optimum tuz miktarı 21 g/l'dir. Bu değerden $\pm \%20$, $\pm \%25$, $\pm \%30$ farklı olan tuz konsantrasyonları ile denemeler yapılmıştır. Her bir deneme beş defa tekrar edilmiştir. Bu denemelere ilişkin renk ölçüm sonuçları tablo 3.1 ve 3.2'de görülmektedir.

Tablo3.2 Tuz miktarının pembe boyama üzerine etkisi

Tuz miktarı (g/l)	ΔL^*	ΔC^*	ΔH^*	ΔE
16,80 (-%20)	0,05	0,43	-0,05	0,43
	-0,09	0,18	-0,27	0,34
	0,16	0,52	-0,13	0,56
	0,42	0,06	-0,19	0,46
	0,43	-0,14	-0,13	0,47
15,75 (-%25)	-0,07	0,14	-0,08	0,18
	0,57	0,39	-0,24	0,73
	0,33	0,57	-0,49	0,82
	0,65	-0,01	-0,41	0,76
	0,14	-0,30	-0,14	0,36
14,70 (-%30)	-0,02	0,01	-0,53	0,53
	1,25	0,59	-0,48	1,46
	0,51	0,42	-0,24	0,71
	0,98	0,06	-0,34	1,03
	0,41	-0,35	-0,23	0,59
25,20 (+%20)	-0,65	0,27	-0,03	0,70
	-0,46	0,08	-0,03	0,47
	-0,41	0,35	0,23	0,58
	-0,21	0,24	-0,14	0,34
	-0,62	-0,03	-0,04	0,62
26,25 (+%25)	-0,87	0,25	0,25	0,93
	0,13	0,2	-0,14	0,28
	-0,49	0,49	-0,04	0,70
	-0,32	0,22	0,03	0,40
	-0,26	0,21	0,08	0,34
27,30 (+%30)	-0,62	0,31	0,06	0,70
	-0,30	0,16	-0,08	0,36
	-0,13	0,91	0,17	0,94
	-0,28	0,57	-0,11	0,64
	-0,46	-0,20	-0,02	0,50

3.1.2 Alkali Miktarı

Kahverengi ve pembe boyamalar (%1,55'lik) için, boyama kataloğunda laboratuvar koşulları için belirlenmiş olan optimum alkali miktarı 6 g/l'dir. Bu değerden $\pm$ %20, $\pm$ %25, $\pm$ %30 farklı olan alkali konsantrasyonları ile denemeler yapılmıştır. Her bir deneme beş defa tekrar edilmiştir. Bu denemelere ilişkin renk ölçüm sonuçları tablo 3.3 ve 3.4'de görülmektedir.

Tablo3.3 Alkali miktarının kahverengi boyama üzerine etkisi

Alkali miktarı (g/l)	ΔL^*	ΔC^*	ΔH^*	ΔE
4,8 (-%20)	0,31	-0,07	0,01	0,31
	0,28	0,13	0,24	0,39
	0,19	-0,40	-0,27	0,52
	0,53	0,11	0,02	0,54
	0,26	-0,30	-0,33	0,52
4,5 (-%25)	0,47	-0,03	0,16	0,50
	-0,07	0,01	-0,03	0,08
	0,26	-0,53	-0,22	0,63
	0,30	0,34	0,35	0,58
	0,39	-0,21	-0,14	0,46
4,2 (-%30)	0,98	0,19	0,25	1,03
	-0,21	-0,05	0,05	0,22
	-0,01	-0,43	-0,18	0,47
	0,04	0,36	0,32	0,48
	0,36	0,26	0,17	0,48
7,2 (+%20)	0,64	0,05	0,19	0,67
	-0,10	-0,08	0,18	0,22
	-0,27	-0,09	-0,20	0,35
	-0,41	0,10	0,12	0,44
	0,17	-0,17	0,00	0,24
7,5 (+%25)	0,09	0,20	0,30	0,37
	0,07	0,40	0,21	0,45
	-0,34	-0,01	-0,03	0,34
	0,05	-0,48	-0,26	0,55
	0,08	0,15	0,01	0,17
7,8 (+%30)	0,44	-0,05	0,08	0,45
	-0,16	-0,31	-0,03	0,35
	0,19	-0,25	-0,14	0,34
	0,08	-0,13	-0,02	0,15
	-0,26	-0,52	-0,24	0,62

Tablo3.4 Alkali miktarının pembe boyama üzerine etkisi

Alkali miktarı (g/l)	ΔL^*	ΔC^*	ΔH^*	ΔE
4,8 (-%20)	-0,39	0,16	-0,14	0,45
	-0,25	0,00	-0,15	0,29
	-0,01	0,43	-0,15	0,46
	0,28	-0,01	-0,03	0,28
	0,11	0,07	-0,35	0,38
4,5 (-%25)	-0,50	0,46	0,13	0,69
	0,44	0,16	-0,45	0,65
	0,06	0,41	-0,15	0,44
	0,43	0,14	-0,19	0,49
	0,35	0,06	-0,25	0,44
4,2 (-%30)	-0,22	0,23	0,07	0,33
	-0,12	0,13	-0,27	0,33
	-0,06	0,51	-0,27	0,58
	0,35	0,05	-0,06	0,36
	-0,10	-0,06	0,14	0,18
7,2 (+%20)	-0,88	0,05	-0,06	0,88
	-0,07	0,59	-0,52	0,79
	-0,02	0,33	0,20	0,39
	0,51	0,42	-0,10	0,67
	0,13	0,22	-0,29	0,38
7,5 (+%25)	-0,34	0,25	0,03	0,42
	-0,33	0,22	-0,29	0,49
	-0,27	0,58	-0,19	0,67
	0,15	0,49	-0,07	0,52
	0,10	-0,05	-0,13	0,17
7,8 (+%30)	-0,44	0,13	-0,22	0,51
	-0,19	0,38	-0,28	0,51
	-0,28	0,21	-0,21	0,41
	0,43	0,47	-0,21	0,67
	0,06	-0,03	-0,42	0,42

3.1.3 Boyama Süresi

Boyama kataloğunda laboratuvar koşulları için belirlenmiş olan optimum fiksaj süresi 75 dakikadır. Bunun yanı sıra denemeler 30, 45, 60, 85 ve 95 dakika fiksaj sürelerinde de gerçekleştirilmiştir. Bu denemelere ilişkin renk ölçüm sonuçları tablo 3.5 ve 3.6’da görülmektedir.

Tablo 3.5 Boyama süresinin kahverengi boyama üzerine etkisi

Boyama süresi (dak.)	ΔL^*	ΔC^*	ΔH^*	ΔE
30	0,78	0,42	-0,12	0,90
	0,52	0,16	-0,08	0,55
	0,51	-0,19	-0,35	0,65
	0,97	-0,15	-0,27	1,02
	0,84	0,58	-0,08	1,03
45	0,75	0,56	0,19	0,96
	0,20	0,11	0,05	0,23
	0,43	0,31	0,05	0,54
	0,34	0,00	-0,02	0,34
	-0,40	0,27	-0,17	0,52
60	0,50	0,33	0,11	0,61
	0,03	0,16	-0,04	0,16
	-0,16	-0,25	-0,13	0,32
	-0,02	0,03	0,01	0,04
	-0,15	0,22	0,32	0,42
85	-0,05	-0,05	-0,15	0,17
	-0,02	-0,25	-0,21	0,32
	-0,22	-0,35	-0,10	0,42
	0,04	-0,04	0,08	0,10
	-0,12	-0,07	-0,04	0,15
95	-0,33	-0,20	-0,23	0,45
	0,28	-0,31	-0,10	0,43
	0,45	-0,67	-0,24	0,84
	-0,01	-0,35	-0,17	0,39
	-0,22	-0,37	-0,02	0,44

Tablo 3.6 Boyama süresinin pembe boyama üzerine etkisi

Boyama süresi (dak.)	ΔL^*	ΔC^*	ΔH^*	ΔE
30	1,50	-0,26	-0,38	1,57
	0,68	0,47	-0,30	0,88
	0,85	0,57	-0,08	1,03
	0,62	0,62	-0,09	0,88
	0,27	1,41	-1,56	2,12
45	0,06	0,08	-0,17	0,20
	0,11	0,23	-0,12	0,28
	-0,01	0,18	-0,09	0,21
	0,26	0,29	-0,03	0,39
	-0,40	0,28	-0,17	0,52
60	0,01	0,00	-0,18	0,18
	0,14	0,06	0,19	0,24
	0,06	0,08	-0,04	0,11
	-0,31	0,30	-0,01	0,43
	-0,04	-0,15	-0,02	0,15
85	-0,20	-0,20	-0,38	0,47
	-0,27	-0,25	0,04	0,37
	0,00	-0,19	-0,43	0,47
	0,05	0,02	-0,06	0,08
	-0,47	-0,02	0,25	0,54
95	0,29	-0,14	-0,30	0,44
	-0,36	-0,37	-0,04	0,51
	-0,05	-0,05	-0,30	0,31
	-0,10	0,10	-0,25	0,29
	-0,34	-0,04	-0,04	0,35

3.1.4 Boyama Sıcaklığı

Boyama kataloğunda laboratuvar koşulları için belirlenmiş olan optimum boyama sıcaklığı 82°C'dir. Boyama sıcaklığı 82°C ile 70, 75, 85 ve 90°C'lerdeki boyama sonuçları birbirleriyle karşılaştırılmıştır. Bu denemelere ilişkin renk ölçüm sonuçları tablo 3.7 ve 3.8'de görülmektedir.

Tablo 3.7 Boyama sıcaklığının kahverengi boyama üzerine etkisi

Boyama sıcaklığı (°C)	ΔL^*	ΔC^*	ΔH^*	ΔE
70	1,03	0,17	-0,24	1,07
	0,67	0,47	-0,20	0,84
	0,45	0,32	-0,10	0,56
	0,55	0,36	-0,20	0,69
	0,78	0,22	-0,10	0,82
75	0,19	0,38	0,51	0,67
	0,49	0,11	0,26	0,57
	0,04	0,47	0,45	0,65
	0,28	0,34	0,40	0,60
	0,33	0,29	0,30	0,54
85	-0,13	-0,50	0,24	0,57
	0,24	-0,43	0,28	0,56
	1,11	-0,13	0,26	1,15
	0,81	-0,03	0,36	0,88
	0,78	-0,24	0,28	0,86
90	-0,15	-0,31	0,42	0,55
	0,04	-0,06	0,33	0,34
	0,64	-0,17	0,18	0,68
	0,08	-0,31	0,26	0,42
	0,23	-0,26	0,27	0,44

Tablo 3.8 Boyama sıcaklığının pembe boyama üzerine etkisi

Boyama sıcaklığı (°C)	ΔL^*	ΔC^*	ΔH^*	ΔE
70	0,69	0,24	0,51	0,88
	0,72	0,30	0,64	1,01
	0,65	0,26	0,56	0,90
	0,99	0,44	0,58	1,23
	0,90	0,42	0,44	1,08
75	0,17	0,36	0,63	0,74
	0,44	0,30	0,80	0,96
	0,14	0,46	0,51	0,70
	0,12	0,36	0,61	0,71
	0,49	0,41	0,22	0,68
85	0,09	-0,26	0,07	0,29
	-0,07	-0,28	0,07	0,29
	-0,58	-0,47	0,09	0,75
	-0,08	-0,14	-0,14	0,21
	-0,19	-0,27	-0,04	0,33
90	0,66	-0,16	-0,70	0,98
	0,94	-0,14	-0,16	0,96
	1,01	-0,04	-0,31	1,06
	0,90	-0,07	-0,41	0,99
	1,12	-0,24	-0,45	1,24

3.1.5 Flotte Oranı

Boyama katalogunda laboratuvar koşulları için belirlenmiş olan optimum flotte oranı 1:8'dir. Bu değerden daha kısa (1:5) ve daha uzun (1:10, 1:12) flotte oranları ile de denemeler yapılmıştır. Bu denemelere ilişkin renk ölçüm sonuçları tablo 3.9 ve 3.10'da görülmektedir.

Tablo 3.9 Flotte oranının kahverengi boyama üzerine etkisi

Flotte oranı	ΔL^*	ΔC^*	ΔH^*	ΔE
1/5	0,24	0,23	0,13	0,36
	-1,13	0,74	0,17	1,36
	-0,47	0,54	0,26	0,76
	-0,13	1,09	0,22	1,12
	-0,02	0,14	0,02	0,14
1/10	1,05	-0,19	0,08	1,07
	0,42	-0,23	0,54	0,72
	0,88	-0,45	-0,14	0,99
	0,82	0,06	0,63	1,04
	1,30	-0,57	-0,16	1,43
1/12	1,79	-1,20	-0,64	2,25
	1,71	-0,83	0,68	2,02
	1,34	-1,37	-0,81	2,08
	1,53	-0,41	0,64	1,71
	1,92	-0,94	-0,32	2,16

Tablo 3.10 Flotte oranının pembe boyama üzerine etkisi


Flotte oranı	ΔL^*	ΔC^*	ΔH^*	ΔE
1/5	-0,81	-0,09	0,69	1,07
	-0,49	-0,11	0,70	0,87
	-1,03	-0,02	0,32	1,08
	-0,64	0,07	0,47	0,79
	-0,56	0,00	0,83	1,00
1/10	0,59	0,09	0,05	0,60
	1,17	-0,40	0,10	1,24
	0,37	0,15	0,10	0,42
	0,75	-0,26	-0,07	0,80
	0,56	-0,42	0,01	0,70
1/12	0,94	0,13	-0,27	0,99
	1,60	-0,53	-0,84	1,88
	0,90	0,24	-0,52	1,07
	1,62	-0,50	-0,53	1,78
	1,31	-0,37	-0,61	1,49

3.2 Laboratuvar Parametrelerinin İstatistiksel Olarak Değerlendirilmesi

Laboratuvar parametre denemeleri sonuçları bir istatistik programı olan Minitab'da analiz edilmiştir.

3.2.1 Tuz Miktarı


Kahverengi için;



Şekil 3.1 Tuz miktarı-ΔE için normallik testi


Farklı tuz konsantrasyonları için ortalama $\Delta E = 0,68$, standart sapma $0,254$ 'tür. En düşük ΔE değeri $0,17$, en yüksek ΔE değeri ise $1,20$ 'dir. P değeri $0,244$ bulunur. Farklı tuz konsantrasyonları ($\pm\%20$, $\pm\%25$, $\pm\%30$) ile ΔE arasındaki fark istatistiksel olarak anlamlı değildir ($p > 0,05$). Tuz konsantrasyonunda $\pm\%30$ 'a kadar olan değişimlerin, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Şekil 3.2'de tuz miktarı- ΔE boxplot grafiği gösterilmiştir. Bu grafiğe göre; tuz miktarı $14,70$ g/l ($-\%30$) olduğunda ortalama ΔE ($0,92$); $26,25$ g/l ($+\%25$) olduğunda ise standart sapma ($0,306$) en yüksek olmaktadır. Tuz miktarı $15,75$ g/l ($-\%25$) olduğunda standart sapma ($0,134$) en düşük değerine ulaşmaktadır.



Şekil 3.2 Boxplot (tuz miktarı- ΔE)

Pembe için;




Şekil 3.3 Tuz miktarı- ΔE için normallik testi

Farklı tuz konsantrasyonları için ortalama $\Delta E=0,59$, standart sapma 0,263'tür. En düşük ΔE değeri 0,18, en yüksek ΔE değeri ise 1,46'dır. P değeri 0,134 bulunur. Farklı tuz konsantrasyonları ($\pm\%20$, $\pm\%25$, $\pm\%30$) ile ΔE arasındaki fark istatistiksel

olarak anlamlı değildir ($p>0,05$). Tuz konsantrasyonunda $\pm\%30$ 'a kadar olan değişimlerin, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Şekil 3.4'de tuz miktarı- ΔE boxplot grafiği gösterilmiştir. Bu grafiğe göre; tuz miktarı 14,70 g/l ($-\%30$) olduğunda ortalama ΔE (0,86) ve standart sapma (0,385) en yüksek olmaktadır. Tuz miktarı 16,80 g/l ($-\%20$) olduğunda ise standart sapma (0,079) en düşük değerine ulaşmaktadır.




Şekil 3.4 Boxplot (tuz miktarı- ΔE)

Kahverengi ve pembe için tuz miktarına göre kıyaslama yapacak olursak; kahverengide ortalama ΔE pembeye göre daha yüksektir. Standart sapma, pembede daha yüksek olmakla birlikte değerler birbirine oldukça yakındır. Ortalama ΔE 'nin en düşük olduğu (0,51) tuz miktarı kahverengide 27,30 g/l ($+\%30$), pembede (0,45) ise 16,80 g/l ($-\%20$)'dir.

3.2.2 Alkali Miktarı


Kahverengi için;



Şekil 3.5 Alkali miktarı-ΔE için normallik testi


Farklı alkali konsantrasyonları için ortalama $\Delta E=0,43$, standart sapma 0,187'dir. En düşük ΔE değeri 0,08, en yüksek ΔE değeri ise 1,03'tür. P değeri 0,33 bulunur. Farklı alkali konsantrasyonları ($\pm\%20$, $\pm\%25$, $\pm\%30$) ile ΔE arasındaki fark istatistiksel olarak anlamlı değildir ($p>0,05$). Alkali konsantrasyonunda $\pm\%30$ 'a kadar olan değişimlerin, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Şekil 3.6'da alkali miktarı- ΔE boxplot grafiği gösterilmiştir. Bu grafiğe göre; alkali miktarı 4,2 g/l ($-\%30$) olduğunda ortalama ΔE (0,53) ve standart sapma (0,297) en yüksek olmaktadır. Alkali miktarı 4,8 g/l ($-\%20$) olduğunda ise standart sapma en düşük (0,101) değerine ulaşmaktadır.



Şekil 3.6 Boxplot (alkali miktarı- ΔE)

Pembe için;




Şekil 3.7 Alkali miktarı- ΔE için normallik testi

Farklı alkali konsantrasyonları için ortalama $\Delta E=0,47$, standart sapma 0,167'dir. En düşük ΔE değeri 0,17, en yüksek ΔE değeri ise 0,88'dir. P değeri 0,306 bulunur. Farklı alkali konsantrasyonları ($\pm\%20$, $\pm\%25$, $\pm\%30$) ile ΔE arasındaki fark

istatistiksel olarak anlamlı değildir ($p>0,05$). Alkali konsantrasyonunda $\pm\%30$ 'a kadar olan değişimlerin, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Şekil 3.8'de alkali miktarı- ΔE boxplot grafiği gösterilmiştir. Bu grafiğe göre; alkali miktarı 7,2 g/l ($+\%20$) olduğunda ortalama ΔE (0,62) ve standart sapma (0,228) en yüksek olmaktadır. Alkali miktarı 4,8 g/l ($-\%20$) olduğunda ise standart sapma en düşük (0,085) değerine ulaşmaktadır.




Şekil 3.8 Boxplot (alkali miktarı- ΔE)

Kahverengi ve pembe için alkali miktarına göre kıyaslama yapacak olursak; kahverengide ortalama ΔE pembeye göre daha düşük olmakla birlikte değerler birbirine oldukça yakındır. Standart sapma, kahverengide daha yüksektir. Ortalama ΔE 'nin en düşük olduğu (0,37) alkali miktarı kahverengide 7,5 g/l ($+\%25$), pembe (0,35) ise 4,2 g/l ($-\%30$)'dir.

3.2.3 Boyama Süresi


Kahverengi için;



Şekil 3.9 Boyama süresi- ΔE için normallik testi


Farklı boyama süreleri için ortalama $\Delta E=0,48$, standart sapma $0,287$ 'dir. En düşük ΔE değeri $0,04$, en yüksek ΔE değeri ise $1,03$ 'tür. P değeri $0,139$ bulunur. Farklı boyama süreleri (30, 45, 60, 85 ve 95 dak.) ile ΔE arasındaki fark istatistiksel olarak anlamlı değildir ($p>0,05$). Boyamada uygulanan 5 farklı fikse süresinin, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Şekil 3.10'da boyama süresi- ΔE boxplot grafiği gösterilmiştir. Bu grafiğe göre; boyama süresi 30 dak. olduğunda ortalama ΔE ($0,83$); 45 dak. olduğunda ise standart sapma ($0,278$) en yüksek olmaktadır. Boyama süresi 85 dak. olduğunda standart sapma ($0,133$) en düşük değerine ulaşmaktadır.



Şekil 3.10 Boxplot (boyama süresi- ΔE)

Pembe için;




Şekil 3.11 Boyama süresi- ΔE için normallik testi

Farklı boyama süreleri için ortalama $\Delta E=0,52$, standart sapma $0,47$ 'dir. En düşük ΔE değeri $0,08$, en yüksek ΔE değeri ise $2,12$ 'dir. P değeri $0,005$ bulunur. Farklı boyama süreleri (30, 45, 60, 85 ve 95 dak.) ile ΔE arasındaki fark istatistiksel olarak

anlamlıdır ($p<0,05$). Boyamada uygulanan farklı fikse sürelerinin, referans boyamaya göre farklılığa neden olduğunu söyleyebiliriz.

Şekil 3.12’de boyama süresi- ΔE boxplot grafiği gösterilmiştir. Bu grafiğe göre; boyama süresi 30 dak. olduğunda ortalama ΔE (1,29) ve standart sapma (0,54) en yüksek olmaktadır. Boyama süresi 95 dak. olduğunda ise standart sapma (0,09) en düşük değerine ulaşmaktadır.




Şekil 3.12 Boxplot (boyama süresi- ΔE)

Kahverengi ve pembe için boyama süresine göre kıyaslama yapacak olursak; kahverengide ortalama ΔE ve standart sapma pembeye göre daha düşüktür. Ortalama ΔE ’nin en düşük olduğu boyama süresi kahverengide 85 dak. (0,23), pembe ise 60 dak. (0,22)’dir.

3.2.4 Boyama Sıcaklığı


Kahverengi için;



Şekil 3.13 Boyama sıcaklığı-ΔE için normallik testi


Farklı boyama sıcaklıkları için ortalama $\Delta E = 0,67$, standart sapma 0,208'dir. En düşük ΔE değeri 0,34, en yüksek ΔE değeri ise 1,15'dir. P değeri 0,146 bulunur. Farklı boyama sıcaklıkları (70, 75, 85, 90°C) ile ΔE arasındaki fark istatistiksel olarak anlamlı değildir ($p > 0,05$). Boyamada uygulanan 4 farklı boyama sıcaklığının, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Şekil 3.14'de boyama sıcaklığı-ΔE boxplot grafiği gösterilmiştir. Bu grafiğe göre; boyama sıcaklığı 85°C olduğunda ortalama ΔE (0,80) ve standart sapma (0,246) en yüksek olmaktadır. Boyama süresi 75°C olduğunda ise standart sapma (0,05) en düşük değerine ulaşmaktadır.



Şekil 3.14 Boxplot (boyama sıcaklığı- ΔE)

Pembe için;




Şekil 3.15 Boyama sıcaklığı- ΔE için normallik testi

Farklı boyama sıcaklıkları için ortalama $\Delta E=0,79$, standart sapma 0,31'dir. En düşük ΔE değeri 0,21, en yüksek ΔE değeri ise 1,24'tür. P değeri 0,051 bulunur. Farklı boyama sıcaklıkları (70, 75, 85, 90°C) ile ΔE arasındaki fark istatistiksel

olarak anlamlı değildir ($p>0,05$). Boyamada uygulanan 4 farklı boyama sıcaklığının, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Şekil 3.16’da boyama sıcaklığı- ΔE boxplot grafiği gösterilmiştir. Bu grafiğe göre; boyama sıcaklığı 90°C olduğunda ortalama ΔE (1,04); 85°C olduğunda ise standart sapma (0,214) en yüksek olmaktadır. Boyama süresi 90°C olduğunda standart sapma (0,114) en düşük değerine ulaşmaktadır.




Şekil 3.16 Boxplot (boyama sıcaklığı- ΔE)

Kahverengi ve pembe için boyama sıcaklığına göre kıyaslama yapacak olursak; kahverengide ortalama ΔE ve standart sapma pembeye göre daha düşüktür. Ortalama ΔE 'nin en düşük olduğu boyama sıcaklığı kahverengide 90°C (0,48), pembede ise 85°C (0,37)'dir.

3.2.5 Flotte Oranı


Kahverengi için;




Şekil 3.17 Flotte oranı-ΔE için normallik testi

Farklı flotte oranları için ortalama $\Delta E=1,28$, standart sapma 0,657'dir. En düşük ΔE değeri 0,14, en yüksek ΔE değeri ise 2,25'dir. P değeri 0,602 bulunur. Farklı flotte oranları (1/5, 1/10, 1/12) ile ΔE arasındaki fark istatistiksel olarak anlamlı değildir ($p>0,05$). Boyamada uygulanan 3 farklı flotte oranının, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Şekil 3.18'de flotte oranı-ΔE boxplot grafiği gösterilmiştir. Bu grafiğe göre; flotte oranı 1/12 olduğunda ortalama ΔE (2,04); 1/5 olduğunda ise standart sapma (0,508) en yüksek olmaktadır. Flotte oranı 1/12 olduğunda standart sapma (0,205) en düşük değerine ulaşmaktadır.

Şekil 3.18 Boxplot (flotte oranı- ΔE)


Pembe için;

Şekil 3.19 Flotte oranı- ΔE için normallik testi

Farklı flotte oranları için ortalama $\Delta E=1,05$, standart sapma 0,409'dur. En düşük ΔE değeri 0,42, en yüksek ΔE değeri ise 1,88'dir. P değeri 0,273 bulunur. Farklı

flotte oranları (1/5, 1/10, 1/12) ile ΔE arasındaki fark istatistiksel olarak anlamlı değildir ($p>0,05$). Boyamada uygulanan 3 farklı flotte oranının, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Şekil 3.20’de flotte oranı- ΔE boxplot grafiği gösterilmiştir. Bu grafiğe göre; flotte oranı 1/12 olduğunda ortalama ΔE (1,44) ve standart sapma (0,403) en yüksek olmaktadır. Flotte oranı 1/5 olduğunda standart sapma (0,127) en düşük değerine ulaşmaktadır.



Şekil 3.20 Boxplot (flotte oranı- ΔE)

Kahverengi ve pembe için flotte oranına göre kıyaslama yapacak olursak; kahverengide ortalama ΔE ve standart sapma pembeye göre daha yüksektir. Ortalama ΔE ’nin en düşük olduğu flotte oranı kahverengide 1/5 (0,74), pembe ise 1/10 (0,75)’dur.

3.3 Yapay Sinir Ağları ile Reçete Tahmini Sonuçları


Materyal ve yöntem kısmında belirtildiği gibi, yapay sinir ağlarında bir sistemi eğitmek için kullanılan çeşitli metotlar vardır. Bu tez çalışmasında, yapay sinir ağlarının RBF ve MLP metotları kullanılmıştır. Her iki metot da bazı avantaj ve dezavantajlara sahiptir. Aynı veri grubu ile bu iki metot da kullanılarak karşılaştırma yapılmıştır. Ayrıca bu metotlardaki çeşitli parametreler değiştirilerek, bu parametrelerin sonuçları nasıl etkilediği gözlemlenmiştir.

3.3.1 Uygulama (1) Sonuçları

3.3.1.1 RBF Uygulamaları


Matlab’da RBF ile bağlantılı dört fonksiyon mevcuttur. Bu fonksiyonlar; newrbe, newrb, newgrnn ve newpnn’dir. Uygulamalar bu dört fonksiyonla da yapılmıştır. Sonuçlar gözlemlendikten sonra, newrbe ve newrb’nin diğer fonksiyonlara göre daha başarılı olduğu bulunmuştur. Bu nedenle sadece bu iki fonksiyon ile uygulamalara devam edilerek, sonuçlar gösterilmiştir.

Newrbe fonksiyonunun uygulama aşamasında bazı değişiklikler yapılmıştır. İlk olarak, RBF uygulamalarında en önemli parametre olan “spread”in kesin değerinin bulunmasına çalışılmıştır. Veri tipine bağlı olarak değişen girdiler ve üç çıktı ile ağ oluşturulmuştur. Sisteme farklı spread değerleri verilerek sonuçlar gözlemlenmiştir. Bu spread değerleri sisteme manuel olarak verilmiştir. Uygulama sonucunda, bir spread değerinde kırmızı renk konsantrasyonunun sarı ve maviye göre eğitimde daha başarılı olduğu; diğer bir spread değerinde ise sarı renk konsantrasyonunun kırmızı ve maviye göre daha başarılı olduğu görülmüştür. Bu sonuçlar göz önüne alındığında, tüm renk konsantrasyonlarını aynı spread değeri ile eğitmenin çok zor olduğu anlaşılmıştır.




Şekil 3.21 Spread değeri=1 ile yapılan eğitim

Şekil 3.21’de de gösterildiği gibi, spread değeri 1 alınarak sistem eğitilmiştir. Bu spread değeri ile sonuçta tüm çıktılar farklı hata yüzdeleri vermiştir.




Şekil 3.22 Hata değerleri (şekil 3.21 için)



Şekil 3.23 Spread değeri=3 ile yapılan eğitim


Spread değiştiğinde sistemin hata değeri de değişmektedir. Bu durum spread'in, RBF eğitiminde çok önemli bir parametre olduğunu gösterir. Doğru spread değerinin seçimi hatayı azaltmaktadır.

Sonuçlara bakıldığında her çıktı için farklı bir spread değerinin gerekli olduğu anlaşılır. Bu nedenle bir sonraki uygulamada her çıktı için farklı spread değeri seçimi denenmiştir.




Şekil 3.24 Hata değerleri (şekil 3.23 için)

Kırmızı, mavi ve sarı renklerin farklı spread değerleri ile eğitilmesine karar verilmiştir. Bu renklerin farklı spread değerleri ile eğitilmesi, her renk için farklı bir ağı oluşturulması ile mümkündür. Bu nedenle üç farklı ağ oluşturulmuştur ve üç farklı spread değeri ağlara manuel olarak verilmiştir. Bu metotla, ağların tek bir ağa kıyasla daha iyi bir şekilde eğitildiği gözlemlenmiştir. Spread değerlerinin manuel olarak verilmesi bir dezavantaj oluşturmaktadır. Oluşturulan üç ağ yapısı için, ayrı ayrı en doğru spread değerlerini belirlemek oldukça zordur.




Şekil 3.25 Farklı ağırlar ve spread değerleri ile eğitim

Sistem üç farklı ağırlık ve üç farklı spread değeri ile eğitilmiştir. Şekil 3.25'te görüldüğü gibi, kırmızı çıktı spread değeri 1 ile, mavi çıktı spread değeri 5 ile, sarı çıktı spread değeri 10 ile eğitilmiştir. Bu spread değerleri manuel olarak seçilmiştir. Doğru spread değerinin seçilmesi eğitim işleminde çok önemlidir ve bu işlemi manuel olarak gerçekleştirmek oldukça zordur. Bu nedenle, bir sonraki uygulamada spread değerlerinin otomatik olarak seçimi denenmiştir.




Şekil 3.26 Hata değerleri (şekil 3.25 için)

Spread değerlerinin manuel olarak seçilmesi probleminin üstesinden gelebilmek için, belirli bir aralıkta spread değerlerini hesaplayan bir alt program, programa eklenmiştir. Bu program sayesinde, belirli bir aralıktaki tüm değerler spread değeri olarak denenmiş ve ağlar için en az hatayı veren değer hesaplanarak, otomatik olarak seçilmiştir. Bu yöntemle üç ağda da başarı sağlanarak, birbirine yakın performanslar elde edilmiştir.




Şekil 3.27 Renklere göre spread dağılımı

Şekil 3.27’deki grafiğe göre, 0-100 arasındaki spread değerleri hata değerlerine göre verilmiştir.




Şekil 3.28 Üç farklı ağ için otomatik spread değerleri

Şekil 3.28’de görüldüğü gibi, spread değerleri şekil 3.27’deki grafikten otomatik olarak verilmiştir. Bu spread değerleri otomatik olarak hesaplama yapan alt program sayesinde belirlenmiştir. En az hataya karşılık gelen spread değerleri eğitimde kullanılır. Bu yöntemle hata değerleri üç renk için de azalmış ve birbirine yaklaşmıştır.




Şekil 3.29 Otomatik spreadler için hata değerleri

Ağın kırmızı, mavi ve sarı olarak tanımlanan çıktıları belirli değerlere sahiptir. Ağın eğitilmesinden sonra, test setinde kullanılan verilerin çıktıları, elimizde bulunmayan çıktı değerlerine gitmektedir. Bu nedenle hata oranı yüksektir. Bu problemin üstesinden gelmek amacıyla, sonuçta elde edilen çıktı değerleri en yakın çıktı değerine yuvarlanmıştır. Sistemin hata oranı bu yolla önemli ölçüde düşürülmüştür.




Şekil 3.30 Renklere göre spread dağılımı

Şekil 3.30'daki grafiğe göre, 0-100 arasındaki spread değerleri hata değerlerine göre verilmiştir.




Şekil 3.31 Yuvarlama işleminden sonra çıktı dağılımı

Çıktı değerlerine yuvarlama işlemi yapılmıştır. Bu işlem sonucunda hata yüzdelерinin önemli ölçüde düştüğü görülmüştür. Renklere göre yüzdelер yaklaşık 0-2 civarındadır.




Şekil 3.32 Yuvarlama işleminden sonra hata değerleri

Yuvarlama işleminden sonra, hata değerlerinin genliklerinin düştüğü gözlemlenmiştir. Şekil 3.32’de görüldüğü gibi, hata değerlerinin niceliği de önemli ölçüde azalmıştır.




Şekil 3.33 Renklere göre spread dağılımı

Şekil 3.33'deki grafiğe göre, 0-3 arasındaki spread değerleri hata değerlerine göre verilmiştir.




Şekil 3.34 Yuvarlama işleminden ve spread değerlerini 0-3 aralığına daralttıktan sonra çıktı dağılımı

Önceki denemelerde seçilen spread değerleri 0-3 aralığındaydı. Spread değerleri 0-100 aralığında ele alınmakla birlikte, bu değerler 1'er adımla ilerlemekteydi. Bu denemede, 0-3 aralığındaki spread değerlerinin daha detaylı incelenmesine ve spread adımlarının 1'den 0,01'e düşürülmesine karar verilmiştir. Spread değerinin daha detaylı bir şekilde hesaplanmasının sistemin başarısını arttırdığı görülmüştür.




Şekil 3.35 Spread dağılımının değişiminin ardından hata değerleri

Spread dağılımı 0-3 aralığına çekildiğinde hata miktarının azaldığı gözlemlenmiştir.




Şekil 3.36 Renklere göre spread dağılımı

Şekil 3.36'daki grafiğe göre, 0-3 arasındaki spread değerleri hata değerlerine göre verilmiştir.



Şekil 3.37 Yuvarlama işleminin, spread aralığını daraltmanın ve eğitimde kullanılan örnek sayısını arttırmanın ardından çıktı dağılımı

Önceki uygulamalarda eğitimde kullanılan örnek sayısının yeterli olmadığı görülmüştür. Bu uygulamada, eğitimde kullanılan örnek sayısı 250'den 400'e çıkarılmıştır. Bu, boyamaların tekrarlarının sayısının 5'den 8' çıkması demektir. Şekil 3.37'de görüldüğü gibi, üç renk için de hata yüzdeleri, %0'a düşürülmüştür.



Şekil 3.38 Eğitimde kullanılan örnek sayısını arttırmanın ardından hata değerleri

Şekil 3.38’de görüldüğü gibi, hata değerleri üç çıktı için de 0’a düşürülmüştür.


Newrb fonksiyonunun uygulanmasında da, newrbe’de açıklanan değişiklikler yapılmıştır. Bunların yanında, newrb’de “goal” adı verilen bir parametre kullanılmıştır. Bu parametreyi değiştirerek, eğitim işleminin ne zaman durdurulacağına karar verilmiştir.

3.3.1.2 MLP Uygulamaları


Matlab’da MLP ile bağlantılı üç fonksiyon mevcuttur. Bu fonksiyonlar; newff, newcf ve newelm’dir. Uygulamalar bu üç fonksiyonla da yapılmıştır. Sonuçlar gözlemlendikten sonra, newff’nin diğer fonksiyonlara göre daha başarılı olduğu bulunmuştur. Bu nedenle sadece bu fonksiyon ile uygulamalara devam edilerek, sonuçlar gösterilmiştir.

MLP’de giriş ve çıkış katmanları arasında bazı gizli katmanlar mevcuttur. Newff fonksiyonu ile uygulamalar sırasında, gizli katmanların ve bu katmanlardaki nöronların sayıları değiştirilmiştir. Gizli katman sayısı ikinin üzerinde olduğunda, sistemin performansı düşmüştür. Aynı şekilde gizli katmandaki nöron sayısının fazla artırılması da performansı düşürmüştür. Gizli katmandaki nöron sayısının ve gizli katman sayısının artırılması, eğitim süresini de önemli ölçüde arttırmıştır. Bu nedenle gizli katman sayısı bir ya da iki olarak alınmıştır.


Bu uygulama için sonuç grafikleri ve grafiklerin açıklamaları aşağıda verilmiştir.




Şekil 3.39 1 gizli katman, 10 gizli nöron ile eğitim performansı




Şekil 3.40 1 gizli katman, 10 gizli nöron ile eğitimin ardından çıktı dağılımı




Şekil 3.41 1 gizli katman 10 gizli nöronlu sistemin hata değerleri




Şekil 3.42 1 gizli katman, 25 gizli nöron ile eğitim performansı




Şekil 3.43 1 gizli katman, 25 gizli nöron ile eğitimin ardından çıktı dağılımı




Şekil 3.44 1 gizli katman 25 gizli nöronlu sistemin hata değerleri



Şekil 3.45 1 gizli katman, 50 gizli nöron ile eğitim performansı



Şekil 3.46 1 gizli katman, 50 gizli nöron ile eğitimin ardından çıktı dağılımı



Şekil 3.47 1 gizli katman 50 gizli nöronlu sistemin hata değerleri

Eğitim aşamasında ilk olarak, gizli nöron sayısı 10'dan 25'e yükseltilmiştir. Eğitim süresinin 9 saniyeden 27 saniyeye yükseldiği görülmüştür. Bununla birlikte eğitim performansı yükselmiş ve hata yüzdeleri düşmüştür.


Sonraki aşamada gizli nöron sayısı 25'den 50'ye yükseltilmiştir. Eğitim süresinin ve hata yüzdelerinin arttığı görülmüştür. Sistemin eğitim performansı da düşmüştür.

Bu denemeler, nöron sayısını çok fazla arttırmanın sistemin iyi bir eğitim performansına sahip olacağı anlamına gelmediğini göstermektedir.


Matlab’da, MLP uygulamalarında, daha önce de belirtildiği gibi newff komutu kullanılmıştır. Bu komutun kullanımını etkileyen parametrelerden biri transfer fonksiyonun seçimidir. Transfer fonksiyon tansig, logsig ya da purelin gibi farklı fonksiyonlar olabilmektedir. Transfer fonksiyonlar sisteme uygulanmıştır. Çıkış katmanında purelin, gizli katmanda logsig fonksiyonlarının kullanılmasına karar verilmiştir.

Eğitim aşamasında etkili olan diğer bir parametre de devir sayısıdır. Devir sayısı, eğitimin tamamlanacağı zamanı belirler. Sistem daha önceden belirlenmiş olan devir sayısına ulaştığında, eğitim tamamlanır. Devir sayısı bir çok defa değiştirilmiş ve bu sayı çok yüksek olduğunda eğitimin kabul edilebilir bir zamanda, bir sonuca yakınsamadığı görülmüştür. Devir sayısı çok düşük olduğunda ise eğitim işlemi başarıya ulaşamamıştır.


Bu uygulama için sonuç grafikleri ve grafiklerin açıklamaları aşağıda verilmiştir.




Şekil 3.48 500 devir sayısı ile eğitim performansı




Şekil 3.49 500 devir sayısı ile eğitimin ardından çıktı dağılımı




Şekil 3.50 500 devir sayısı ile eğitilen sistemin hata değerleri




Şekil 3.51 1000 devir sayısı ile eğitim performansı




Şekil 3.52 1000 devir sayısı ile eğitimin ardından çıktı dağılımı




Şekil 3.53 1000 devir sayısı ile eğitilen sistemin hata değerleri



Şekil 3.54 2000 devir sayısı ile eğitim performansı



Şekil 3.55 2000 devir sayısı ile eğitimin ardından çıktı dağılımı



Şekil 3.56 2000 devir sayısı ile eğitilen sistemin hata değerleri

Eğitim aşamasında ilk olarak, devir sayısı 500'den 1000'e yükseltilmiştir. Eğitim süresinin 5 saniyeden 9 saniyeye yükseldiği görülmüştür. Bununla birlikte eğitim performansı yükselmiş ve hata yüzdeleri düşmüştür.


Sonraki aşamada devir sayısı 1000'den 2000'e yükseltilmiştir. Eğitim süresinin ve hata yüzdelerinin arttığı görülmüştür. Sistemin eğitim performansı da düşmüştür.

Bu denemeler, devir sayısını çok fazla arttırmanın sistemin iyi bir eğitim performansına sahip olacağı anlamına gelmediğini göstermektedir. Belirli bir noktadan sonra sistem genelleme yeteneğini kaybetmektedir.


Üzerinde çalıştığımız son parametre “goal” dır. Goal (hedef değer) belirli bir hata değerinde eğitimi durdurmak için kullanılır. Eğitimi durdurmak için kullandığımız diğer bir parametre de devir sayısıydı. Sistem belirlenen hedef değere ulaşmadan devir sayısına ulaşırsa eğitim durur. Aynı şekilde sistem belirlenen devir sayısına ulaşmadan hedef değere ulaşırsa da sistem durmaktadır. Bu nedenle hedef değere ve devir sayısına dikkatli bir şekilde karar verilmelidir.

RBF’de olduğu gibi, ağın kırmızı, mavi ve sarı olarak tanımlanan çıktıları belirli değerlere sahiptir. Ağın eğitilmesinden sonra, test setinde kullanılan verilerin çıktıları, elimizde bulunmayan çıktı değerlerine gitmektedir. Bu nedenle hata oranı yüksek olmaktadır. Bu problemin üstesinden gelmek amacıyla, sonuçta elde edilen çıktı değerleri en yakın çıktı değerine yuvarlanmıştır. Sistemin hata oranı bu yolla önemli ölçüde düşürülmüştür. Ayrıca veriler sisteme rastgele verilmiştir. Verilerimiz sıralı şekildedir. Bu nedenle verileri doğrudan sisteme verdiğimizde, sistem genelleme yeteneğini kaybetmektedir ve yeni bir veri sisteme girildiğinde, sistem iyi bir şekilde öğrenememektedir. Veriler sisteme rastgele verildiğinde, eğitimin daha başarılı olduğunu söyleyebiliriz.


Bu işlemlerin ardından girdi sayısı değiştirilmiştir. Girdi sayısı 250’den 400’e yükseltilerek sistemdeki değişimler gözlenmiştir.




Şekil 3.57 15 gizli nöron, 250 girdi ile eğitim performansı




Şekil 3.58 15 gizli nöron, 250 girdi ile eğitimin ardından çıktı dağılımı




Şekil 3.59 15 gizli nöron, 250 girdi ile eğitilen sistemin hata değerleri



Şekil 3.60 15 gizli nöron, 400 girdi ile eğitim performansı



Şekil 3.61 15 gizli nöron, 400 girdi ile eğitimin ardından çıktı dağılımı




Şekil 3.62 15 gizli nöron, 400 girdi ile eğitilen sistemin hata değerleri

Eğitimde, girdi sayısı 250'den 400'e yükseltilmiştir. Eğitim süresinin 41 saniyeden 57 saniyeye yükseldiği görülmüştür. Buna rağmen eğitim performansı yükselmiş ve hata yüzdeleri düşmüştür.


Bu deneme, girdi sayısını yükseltmenin eğitim süresini arttırmasına rağmen sistemi olumlu yönde etkilediğini göstermektedir.

Bu işlemlerin ardından son olarak, sisteme ikinci bir gizli katman eklenmesine karar verilmiştir. Sonuç grafikleri aşağıda gösterilmiştir.




Stop Training


Şekil 3.63 2 gizli katmanlı ve ilk katmanda 15, ikinci katmanda 5 nöronlu sistemin eğitim performansı



Şekil 3.64 2 gizli katman ve ilk katmanda 15, ikinci katmanda 5 nöron ile eğitimin ardından çıktı dağılımı




Şekil 3.65 2 gizli katman ve ilk katmanda 15, ikinci katmanda 5 nöron ile eğitilen sistemin hata değerleri




Stop Training


Şekil 3.66 2 gizli katmanlı ve ilk katmanda 15, ikinci katmanda 10 nöronlu sistemin eğitim performansı



Şekil 3.67 2 gizli katman ve ilk katmanda 15, ikinci katmanda 10 nöron ile eğitimin ardından çıktı dağılımı




Şekil 3.68 2 gizli katman ve ilk katmanda 15, ikinci katmanda 10 nöron ile eğitilen sistemin hata değerleri




Stop Training

Şekil 3.69 2 gizli katmanlı ve ilk katmanda 15, ikinci katmanda 15 nöronlu sistemin eğitim performansı



Şekil 3.70 2 gizli katman ve ilk katmanda 15, ikinci katmanda 15 nöron ile eğitimin ardından çıktı dağılımı




Şekil 3.71 2 gizli katman ve ilk katmanda 15, ikinci katmanda 15 nöron ile eğitilen sistemin hata değerleri

Eğitimde ilk olarak, ikinci gizli katmandaki nöron sayısı 5’den 10’a yükseltilmiştir. Eğitim süresinin 102 saniyeden 223 saniyeye yükseldiği görülmüştür. Buna rağmen eğitim performansı yükselmiş ve hata yüzdeleri düşmüştür.


Sonraki aşamada, ikinci gizli katmandaki nöron sayısı 10'dan 15'e yükseltilmiştir. Eğitim süresinin ve hata yüzdelerinin arttığı görülmüştür. Sistemin eğitim performansı da düşmüştür.

Bu denemeler, ikinci gizli katmandaki nöron sayısını çok fazla arttırmanın sistemin iyi bir eğitim performansına sahip olacağı anlamına gelmediğini göstermektedir. Belirli bir sınır söz konusudur.


Son olarak sistem, iki gizli katmanlı ve katmanlarda farklı nöron sayıları ile eğitilmiştir. Sonuçlar aşağıda gösterilmiştir.



Şekil 3.72 2 gizli katmanlı ve ilk katmanda 20, ikinci katmanda 25 nöronlu sistemin eğitim performansı



Şekil 3.73 2 gizli katman ve ilk katmanda 20, ikinci katmanda 25 nöron ile eğitimin ardından çıktı dağılımı




Şekil 3.74 2 gizli katman ve ilk katmanda 20, ikinci katmanda 25 nöron ile eğitilen sistemin hata değerleri

Gizli katman sayısını 2'ye yükseltmenin sistemin performansını arttırdığı görülmüştür. Bu uygulamalarda 3000 devir sayısı kullanılmıştır. Yapılan çok sayıda denemenin ardından, gizli katmanlardaki nöron sayıları 20 ve 25 olarak belirlenmiştir. Şekil 3.72'de görüldüğü gibi, sistem 3000 devir sayısına ulaşmadan, devir sayısı 151 olduğunda eğitim tamamlanmıştır. Şekil 3.74'de görüldüğü gibi üç renk için de hata yüzdeleri %0'a düşmüştür. Bu %100 başarı demektir.


3.3.2 Uygulama (2) Sonuçları

3.3.2.1 MLP Uygulamaları


MLP metodu ile yapılan çok sayıda denemenin ardından ağın optimum durumu belirlenmiştir. En iyi sonuçlar üç gizli katmanlı ağ yapısı ve gizli katmanlarda sırasıyla 20, 15, 10 nöron sayıları ile elde edilmiştir. Denemeler 1000 devir sayısı ile yapılmıştır. Üç renk için çıktı dağılımları ve hata değerleri grafiklerde verilmiştir.




Şekil 3.75 Eğitilen sistem için kırmızı renk çıktı dağılımı




Şekil 3.76 Eğitilen sistem için mavi renk çıktı dağılımı




Şekil 3.77 Eğitilen sistem için sarı renk çıktı dağılımı



Şekil 3.78 Eğitilen sistemin kırmızı renk için hata değerleri



Şekil 3.79 Eğitilen sistemin mavi renk için hata değerleri



Şekil 3.80 Eğitilen sistemin sarı renk için hata değerleri

Uygulamalar sonucunda üç renkte de %0 hata değerine ulaşılammıştır. Kırmızı için %6,2; mavi için %2,8 ve sarı için %4,4 hata yüzdeleri elde edilmiştir. Bu da kırmızı renk için %93,8; mavi renk için %97,2 ve sarı renk için %95,6 başarı demektir.

Uygulama (2)'de daha yüksek başarı beklenmesine rağmen, elde edilen başarı, uygulama (1)'de elde edilenden daha düşük olmuştur. Bu durumu incelediğimizde iki sebep göze çarpmaktadır. Uygulama (1)'de 500 adet boyama ile, uygulama (2)'de 2000 adet boyama ile çalışılmıştır. Boyamaların sayısının artması, girdi değerlerinde hata artışını da beraberinde getirmiştir. Diğer bir neden ise, uygulama (2)'de boyarmadde konsantrasyon değerlerinin daha dar aralıklarla belirlenmiş olmasıdır. Bu da boyamalara ait girdi değerlerinin, birbiri içerisine geçmesine sebep olmuştur. Bunun sonucunda sistem performansı düşmüştür.


3.3.2.2 İşletme Boyamaları için Uygulama Sonuçları

Laboratuvarda yapılan 2000 adet boyamanın ardından, sistemde test edebilmek amacıyla 4 adet de işletme boyaması yapılmıştır. Bu boyamaların 2 tanesi, 100 reçetenin içerisinde seçilen konsantrasyon değerleri ile yapılmıştır. Diğer ikisi için ise ara konsantrasyon değerleri belirlenmiştir. Laboratuvar-işletme uyumu açısından, boyama yöntemleri, yıkama koşulları ve değerlendirme işlemleri, laboratuvar boyamaları ile aynı şekilde yapılmıştır. 20'şer kg'lık 4 adet kumaş, işletmede numune tipi overflow boyama makinelerinde boyanmıştır. Boyama ve yıkama işlemlerinin ardından, kumaşların spektrofotometrede renk ölçümleri yapılarak, CIELab ve reflektans değerleri elde edilmiştir.


İşletmede yapılan 4 adet boyamanın girdi değerleri, uygulama (2) ile elde edilen sisteme verilerek sonuçlar gözlemlenmiştir. İşletme boyamalarının konsantrasyon değerleri bu yolla tahminlenmeye çalışılmıştır.

Tablo 3.11 İşletme reçetelerine ait konsantrasyon değerleri


	Procion Crimson H-EXL	Procion Navy H-EXL	Procion Yellow H-E4R
1	0,40	0,80	0,80
2	1,00	0,40	1,00
3	0,22	0,55	0,22
4	1,10	1,10	0,11



Şekil 3.81 Kırmızı renk çıktı dağılımı



Şekil 3.82 Mavi renk çıktı dağılımı



Şekil 3.83 Sarı renk çıktı dağılımı

İşletme boyamalarının sisteme uygulanması sonucunda, 4 reçete için de hata oranları oldukça yüksek çıkmıştır. Örneğin; 1 nolu reçetede, kırmızı renk için hedef değer (target) 0,40; mavi renk için hedef değer 0,80 ve sarı renk için de 0,80 olmasına karşın, elde edilen konsantrasyon değerleri (output) sırasıyla, 0,80; 0,80 ve 0,40 olmuştur. Buna göre, kırmızı ve sarı renklerde hata oranı %50 demektir. Bu da reçetenin farklılaşması anlamına gelmektedir. 1 ve 2 nolu reçetelerde, 3 ve 4 nolu reçetelere göre daha yaklaşık sonuçlar elde edilmiştir. 1 ve 2 nolu reçeteler, daha önce laboratuvarında boyanmış olan 100 adet reçetenin içerisinde seçilmiştir. 3 ve 4 nolu reçeteler ise, ara konsantrasyon değerleri belirlenerek oluşturulmuştur. Bu nedenle, sistem önceden öğrenmiş olduğu 1 ve 2 nolu reçetelerde, daha yüksek performans değerlerine ulaşmıştır.

3.4 Bulanık Mantık ile Reçete Tahmini Sonuçları

Bulanık mantıkta da yapay sinir ağlarında olduğu gibi farklı metotlar mevcuttur. Bu tez çalışmasında, ağız eğitiminde Adaptive Neuro-Fuzzy Inference System (ANFIS) metodu kullanılmıştır. Bu metodun seçilmesinin nedeni, yapay sinir ağları ile olan bağlantısıdır. ANFIS, isminden de anlaşılacağı gibi, yapay sinir ağları ve bulanık mantığı birlikte içeren hibrid bir sistemdir. Bu metot da kullanılan diğer metotlar gibi bazı avantaj ve dezavantajlara sahiptir. En büyük dezavantajı, yüksek hafıza depolama gereksinimidir. Girdi başına düşen üyelik fonksiyonlarının sayısı ne kadar fazla olursa, sistem o kadar iyi öğrenir. Bu durumda sistem yakınsamak için çok fazla zamana gereksinim duyar. Bu nedenle, üyelik fonksiyonunun artırılması sistemi olumlu yönde etkilemesine rağmen, hafıza limitlerinden ve öğrenme zamanından dolayı bu sayıyı çok fazla arttırmak mümkün olmamaktadır.

3.4.1 Uygulama (1) Sonuçları

3.4.1.1 ANFIS Uygulamaları

ANFIS metodunda çeşitli parametreler değiştirilmiş ve sonuçların sistemi nasıl etkilediği grafiklerde gözlemlenmiştir.


ANFIS’de kullanılan bazı üyelik fonksiyonları mevcuttur. Bunlar; trimf, trapmf, gbellmf, gaussmf, gauss2mf, sigmf, dsigmf, psigmf, pimf, smf, zmf’dir. Yapılan çok sayıda denemenin ardından, gbellmf fonksiyonunun kullanılmasına karar verilmiştir. Bu fonksiyon ANFIS’de en genel kullanıma sahip olan üyelik fonksiyonudur.

Kırmızı, mavi ve sarı renklerin farklı ağlarla eğitilmesine karar verilmiştir. Bunu gerçekleştirmek amacıyla, üç farklı ağ kurulmuştur ve bu ağlar için sistem eğitilmiştir.


RBF ve MLP’de olduğu gibi, ağız kırmızı, mavi ve sarı olarak tanımlanan çıktıları belirli değerlere sahiptir. Ağız eğitilmesinden sonra, test setinde kullanılan verilerin

çıktıları, elimizde bulunmayan çıktı değerlerine gitmektedir. Bu nedenle hata oranı yüksek olmaktadır. Bu problemin üstesinden gelmek amacıyla, sonuçta elde edilen çıktı değerleri en yakın çıktı değerine yuvarlanmıştır. Sistemin hata oranı bu yolla önemli ölçüde düşürülmüştür.


Yukarıda belirtildiği gibi, ANFIS'in eğitimini etkileyen çeşitli parametreler mevcuttur. Bunlardan biri, girdi başına düşen üyelik fonksiyonlarının (MF) sayısıdır. Girdi başına düşen MF sayısı arttığında, sistem daha iyi bir şekilde eğitilmektedir. Bu durum için belirli bir sınır söz konusudur çünkü bilgisayar sisteminde çok yüksek miktarda hafıza boşluğu olması gerekmektedir. Bu sınır nedeniyle, girdi başına düşen MF sayısını çok fazla arttırmak mümkün olmamaktadır. Yapılan bir çok deneme sonucunda bu değerin 4 olarak alınmasına karar verilmiştir.




Şekil 3.84 MF=2 ve 20 devir sayısı ile eğitimin ardından çıktı dağılımı




Şekil 3.85 MF=2 için hata değerleri




Şekil 3.86 MF=4 ve 20 devir sayısı ile eğitimin ardından çıktı dağılımı



Şekil 3.87 MF=4 için hata değerleri



Şekil 3.88 MF=7 ve 20 devir sayısı ile eğitimin ardından çıktı dağılımı




Şekil 3.89 MF=7 için hata değerleri


Eğitimde ilk olarak, MF sayısı 2'den 4'e yükseltilmiştir. Eğitim süresinin 0-1 saniyeden 9 saniyeye yükseldiği görülmüştür. Buna rağmen eğitim performansı yükselmiş ve hata yüzdeleri düşmüştür.

Sonraki aşamada, MF sayısı 4'den 7'ye yükseltilmiştir. Eğitim süresinin ve hata yüzdelerinin arttığı görülmüştür. Eğitim süresi 9 saniyeden 518 saniyeye yükselmiştir. Sistemin eğitim performansı da düşmüştür.


Bu denemeler, MF sayısını çok fazla arttırmanın sistemin iyi bir eğitim performansına sahip olacağı anlamına gelmediğini göstermektedir. Belirli bir sınır söz konusudur.




Şekil 3.90 MF=4 ve 5 devir sayısı ile eğitimin ardından çıktı dağılımı




Şekil 3.91 5 devir sayısı ile eğitilen sistemin hata değerleri




Şekil 3.92 MF=4 ve 20 devir sayısı ile eğitimin ardından çıktı dağılımı



Şekil 3.93 20 devir sayısı ile eğitilen sistemin hata değerleri



Şekil 3.94 MF=4 ve 100 devir sayısı ile eğitimin ardından çıktı dağılımı




Şekil 3.95 100 devir sayısı ile eğitilen sistemin hata değerleri

Eğitimde ilk olarak, devir sayısı 5’den 20’ye yükseltilmiştir. Eğitim süresinin 2 saniyeden 9 saniyeye yükseldiği görülmüştür. Buna rağmen eğitim performansı yükselmiş ve mavi rengin hata yüzdesi düşmüştür.


Sonraki aşamada, devir sayısı 20’den 100’e yükseltilmiştir. Eğitim süresinin 9 saniyeden 47 saniyeye yükseldiği görülmüştür. Hata yüzdeleri yaklaşık olarak yarı yarıya düşmüştür.

Bu denemeler, devir sayısını çok fazla arttırmanın sistemin iyi bir eğitim performansına sahip olacağı anlamına geldiğini göstermektedir. Tüm renk çıktıları bu değişimden olumlu yönde etkilenmiştir.

Son olarak, eğitim veri seti 250’den 400’e yükseltilmiştir. 250 girdi için sonuçlar şekil 3.85’de gösterilmiştir. 400 girdi için sonuçlar şekil 3.87’de gösterilmektedir.



Şekil 3.96 400 girdi sayısı için çıktı dağılımı



Şekil 3.97 400 girdi sayısı için hata değerleri

Eğitimde kullanılan veri seti sayısı 250'den 400'e yükseltilmiştir. Bu yolla, hata yüzdeleri düşürülmüştür. Eğitimde kullanılan veri sayısı, tüm metotlar için sistemin performansını arttırmak açısından çok önemlidir.

BÖLÜM DÖRT

SONUÇLAR

1) Kumaş, boyama ve koşullardaki standardizasyonu sağlayabilmek için düzgünlük ve tekrarlanabilirliği etkileyen birçok parametrenin (tuz miktarı, alkali miktarı, flotte oranı, boyama sıcaklığı, boyama süresi vb.) kontrol altına alınması gerekmektedir. Laboratuvar koşullarında bu parametrelerdeki sapmaların ne gibi sonuçlar ortaya çıkarabileceğini gözlemlemek amacıyla, laboratuvar ortamında denemeler yapılmıştır. İki farklı renk için yapılan denemelerin sonuçları aşağıda detaylı bir şekilde belirtilmiştir.

Kahverengi ve pembe için *tuz miktarına* göre karşılaştırma yapacak olursak; kahverengide, farklı tuz konsantrasyonları için ortalama $\Delta E=0,68$, standart sapma 0,254'tür. Pembede ise ortalama $\Delta E=0,59$, standart sapma 0,263'tür. Kahverengide ortalama ΔE pembeye göre daha yüksektir. Standart sapma, pembede daha yüksek olmakla birlikte değerler birbirine oldukça yakındır. Ayrıca p değerlerine baktığımızda, her iki renk için tuz konsantrasyonunda $\pm\%30$ 'a kadar olan değişimlerin, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Alkali miktarına göre karşılaştırma yapacak olursak; kahverengide, farklı alkali konsantrasyonları için ortalama $\Delta E=0,43$, standart sapma 0,187'dir. Pembede ise ortalama $\Delta E=0,47$, standart sapma 0,167'dir. Kahverengide ortalama ΔE pembeye göre daha düşük olmakla birlikte değerler birbirine oldukça yakındır. Standart sapma, kahverengide daha yüksektir. Ayrıca p değerlerine baktığımızda, her iki renk için alkali konsantrasyonunda $\pm\%30$ 'a kadar olan değişimlerin, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Boyama sürelerine göre karşılaştırma yapacak olursak; kahverengide, farklı boyama süreleri için ortalama $\Delta E=0,48$, standart sapma 0,287'dir. Pembede ise ortalama $\Delta E=0,52$, standart sapma 0,47'dir. Kahverengide ortalama ΔE ve standart sapma pembeye göre daha düşüktür. P değerlerine baktığımızda kahverengi için, boyamada uygulanan 5 farklı fikse süresinin, referans boyamaya göre farklılığa

neden olmadığını söyleyebiliriz. Pembe için ise boyamada uygulanan farklı fikse sürelerinin, referans boyamaya göre farklılığa neden olduğunu söyleyebiliriz.

Boyama sıcaklıklarına göre karşılaştırma yapacak olursak; kahverengide, farklı boyama sıcaklıkları için ortalama $\Delta E=0,67$, standart sapma 0,208'dir. Pembede ise ortalama $\Delta E=0,79$, standart sapma 0,31'dir. Kahverengide ortalama ΔE ve standart sapma pembeye göre daha düşüktür. Ayrıca p değerlerine baktığımızda, her iki renk için boyamada uygulanan 4 farklı boyama sıcaklığının, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

Flotte oranlarına göre karşılaştırma yapacak olursak; kahverengide, farklı flotte oranları için ortalama $\Delta E=1,28$, standart sapma 0,657'dir. Pembede ise ortalama $\Delta E=1,05$, standart sapma 0,409'dur. Kahverengide ortalama ΔE ve standart sapma pembeye göre daha yüksektir. Ayrıca p değerlerine baktığımızda, her iki renk için boyamada uygulanan 3 farklı flotte oranının, referans boyamaya göre farklılığa neden olmadığını söyleyebiliriz.

2) Laboratuvar koşullarında boyamalar sonucu elde edilen verileri yapay sinir ağları ve bulanık mantık ile test edebilmek amacıyla farklı tekrar sayılarında farklı reçetelerle denemeler yapılmıştır. İlk olarak 50 farklı reçete, 10 defa tekrar edilerek 500 adet boyama yapılmıştır (Uygulama 1). Daha sonra reçete ve tekrar sayısının artmasıyla daha yaklaşık sonuçların elde edilebileceği düşünülerek, 100 farklı reçete 20 defa tekrar edilerek 2000 adet boyama yapılmıştır (Uygulama 2).

Uygulama (1) için; Yapay sinir ağı uygulamalarında, RBF ve MLP metotları; bulanık mantık uygulamalarında ise ANFIS metodu kullanılmıştır. Bu metotlar bazı avantaj ve dezavantajlara sahiptir. Bu bölümde, elde edilen sonuçlar detaylı bir şekilde açıklanacaktır.

Yapay sinir ağı uygulamalarında kullanılan yöntemleri kıyaslayacak olursak; RBF'de sistemi etkileyen en önemli parametre, doğru spread değerinin seçimidir. RBF'in en önemli avantajı hızlılık özelliğidir. Çok fazla miktarda veri ile çalışıldığı

zaman bile, eğitim süreleri kısa olabilmektedir. Matlab’da RBF ile bağlantılı bazı fonksiyonlar mevcuttur. En başarılı olan iki fonksiyon ile uygulamalar yapılarak, performansları birbiri ile kıyaslanmıştır. Bu fonksiyonlar; newrbe ve newrb’dir. Denemelerde her iki fonksiyon ile yapılan uygulamalarda benzer sonuçlar ortaya çıkmasına karşın, newrbe bazı avantajlara sahiptir. Newrbe, eğitim işleminde newrb’den daha hızlıdır. Ayrıca eğitim ve test aşamalarında, newrbe daha düşük hata yüzdelere sahiptir. Bu gözlemler sonucunda uygulamaların çoğu newrbe ile yapılmıştır.

Yapay sinir ağı uygulamalarında kullanılan bir diğer yöntem MLP yöntemiydi. Matlab’da MLP ile de bağlantılı bazı fonksiyonlar mevcuttur. Sistemin eğitiminde newff fonksiyonu seçilmiştir. Bu fonksiyonun seçilmesinin nedeni, kullanımının daha kolay olması ve diğerlerine göre daha genel bir fonksiyon olmasıdır. Eğitim işleminin ayarlanmasında bazı parametreler mevcuttur. Bu parametreler; gizli katman sayısı, gizli nöron sayısı, goal (hedef değer) ve devir sayısıdır. Tüm bu parametrelerin aynı anda, doğru değerlere ayarlanması oldukça zor bir iştir. Parametreler arasındaki ilişki, her eğitim işleminde verilerin değerlerine göre çok hassas bir şekilde ayarlanmalıdır. Parametrelerin ayarlanma periyodu ve aynı zamanda sistemin eğitim periyodu oldukça uzundur.

Sistemin eğitiminde son olarak bulanık mantık uygulamaları kapsamında, ANFIS metodu uygulanmıştır. ANFIS’de sistemin eğitimini etkileyen iki parametre mevcuttur. Bunlar; devir sayısı ve üyelik fonksiyonu (MF) sayısıdır. MF sayısını arttırmak sisteme olumlu yönde etki yapmaktadır. ANFIS’in en büyük dezavantajı, üyelik fonksiyonu sayısını arttırırken, hafıza limiti sorununun ortaya çıkmasıdır. Bu nedenle MF sayısını kolayca arttırmak mümkün değildir. Sistemi etkileyen bir diğer parametre devir sayısıdır. Devir sayısını arttırdığımızda, sistem performansı da artmaktadır. Belirli bir sınırdan sonra devir sayısı sisteme etki etmemektedir. Bu nedenle devir sayısı, verilerimiz için belirli bir sınırdan kullanılmıştır.

Denemelerde kullanılan üç farklı metottan, RBF’in MLP ve ANFIS’e göre daha hızlı olduğunu ve daha kesin sonuçlara sahip olduğunu söyleyebiliriz. Ayrıca RBF’in

parametre sayısı diğer iki yönteme göre daha azdır, bu nedenle eğitim için RBF'in uygulanması kolaydır. Bu uygulamada RBF, MLP ve ANFIS'e göre daha fazla avantaja sahiptir diyebiliriz.

MLP ve ANFIS'in sonuçları çoğunlukla aynıdır. MLP'nin eğitim süresi ANFIS'den daha kısadır. Bu nedenle, ANFIS'e kıyasla MLP'nin tercih edildiğini söyleyebiliriz.

Sonuç olarak RBF, en kullanışlı ve en başarılı yöntem olarak göze çarpmaktadır. Daha fazla avantaja sahip olması nedeniyle, sonuçlara bakıldığında daha efektiftir.

Tüm uygulamalarda, eğitimde kullanılan veri sayısı arttığında hata değerlerinin azaldığı görülmektedir. Bu, eğitimde kullanılan veri sayısının sistemin performansı üzerinde önemli bir etkiye sahip olduğu anlamına gelmektedir. Kullanılan tüm yöntemlerde, eğitimde kullanılan veri sayısının en önemli parametre olduğunu söyleyebiliriz.

Uygulama (2) için; MLP metodu ile yapılan çok sayıda denemenin ardından ağın optimum durumu belirlenmiştir. En iyi sonuçlar üç gizli katmanlı ağ yapısı ve gizli katmanlarda sırasıyla 20, 15, 10 nöron sayıları ile elde edilmiştir. Denemeler 1000 devir sayısı ile yapılmıştır.

Uygulama (2)'de, MLP yöntemi ile üç renk için de %0 hata değerine ulaşamamıştır. Kırmızı için %6,2; mavi için %2,8 ve sarı için %4,4 hata yüzdeleri elde edilmiştir. Uygulama (1)'de ise MLP ve RBF yöntemleri ile yapılan denemeler sonucunda %0 hata değerlerine ulaşılmıştır.

Uygulama (2)'de daha yüksek başarı beklenmesine rağmen, elde edilen başarı, uygulama (1)'de elde edilenden daha düşük olmuştur. Bu durumu incelediğimizde iki sebep göze çarpmaktadır. Uygulama (1)'de 500 adet boyama ile, uygulama (2)'de 2000 adet boyama ile çalışılmıştır. Boyamaların sayısının artması, girdi değerlerinde hata artışını da beraberinde getirmiştir. Diğer bir neden ise, uygulama (2)'de

boyarmadde konsantrasyon değerlerinin daha dar aralıklarla belirlenmiş olmasıdır. Bu da boyamalara ait girdi değerlerinin, birbiri içerisine geçmesine sebep olmuştur. Bunun sonucunda sistem performansı düşmüştür.

3) Laboratuvarda yapılan 2000 adet boyamanın ardından, sistemde test edebilmek amacıyla 4 adet de işletme boyaması yapılmıştır. Bu boyamaların 2 tanesi, 100 reçetenin içerisinden seçilen konsantrasyon değerleri ile yapılmıştır. Diğer ikisi için ise ara konsantrasyon değerleri belirlenmiştir. Laboratuvar-işletme uyumu açısından, boyama yöntemleri, yıkama koşulları ve değerlendirme işlemleri, laboratuvar boyamaları ile aynı şekilde yapılmıştır. 20'şer kg'lık 4 adet kumaş, işletmede numune tipi overflow boyama makinelerinde boyanmıştır. Boyama ve yıkama işlemlerinin ardından, kumaşların spektrofotometrede renk ölçümleri yapılarak, CIELab ve reflektans değerleri elde edilmiştir.

İşletme boyamalarının sisteme uygulanması sonucunda, 4 reçete için de hata oranları oldukça yüksek çıkmıştır. 1 ve 2 nolu reçetelerde, 3 ve 4 nolu reçetelere göre daha yaklaşık sonuçlar elde edilmiştir. 1 ve 2 nolu reçeteler, daha önce laboratuvarda boyanmış olan 100 adet reçetenin içerisinden seçilmiştir. 3 ve 4 nolu reçeteler ise, ara konsantrasyon değerleri belirlenerek oluşturulmuştur. Bu nedenle, sistem önceden öğrenmiş olduğu 1 ve 2 nolu reçetelerde, daha yüksek performans değerlerine ulaşmıştır.

Sonuç olarak; bu çalışma kapsamında yapılan denemelerde, teoride elde edilen başarılarından yola çıkılarak, pratikle uyum konusunda eksik yönler gözlemlenmiştir. Gerek veri sayısının arttırılması, gerekse verilerin niteliği açısından yapılan yorumlarla sonraki çalışmalara ışık tutulmuştur.

KAYNAKLAR

- Balcı, O. ve Oğulata, R. T. (2008). Boyanmış kumaşlarda kimyasal apre uygulamaları sonucunda oluşabilecek renk değişiminin ve CIELab değerlerinin yapay sinir ağları kullanılarak tahmin edilmesi. *Tekstil ve Konfeksiyon*, 19 (1), 61-69.
- Balcı, O., Oğulata, S. N., Şahin, C. ve Oğulata R. T. (2008). An artificial neural network approach to prediction of the colorimetric values of the stripped cotton fabrics. *Fibers and Polymers*, 9 (5), 604-614.
- Balcı, O. ve Oğulata, R. T. (2009). Prediction of the changes on the CIELab values of fabric after chemical finishing using artificial neural network and linear regression models. *Fibers and Polymers*, 10 (3), 384-393.
- Balcı, O. (2008). *Farklı bitim (apre) işlemlerinin kumaş rengine olan etkisinin incelenmesi ve uygun tahmin modellerinin geliştirilmesi*. Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi.
- Bishop, J. M., Bushnell, M. J. ve Westland, S. (1991). Application of neural network to computer recipe prediction. *Color Research and Application*, 16 (1), 3-8.
- Backpropagation (geri yayılım algoritması)*, (b.t). 10 Ekim 2008, <http://www.backpropagation.netfirms.com/backprop.htm>.
- Cheng, K. P. S. ve Lam, H. L. I. (2003). Evaluating and comparing the physical properties of spliced yarns by regression and neural network techniques. *Textile Research Journal*, 73 (2), 161-164.
- Duran, K. (2001). *Tekstilde renk ölçümü ve reçete çıkarma*. İzmir: Ege Üniversitesi Tekstil ve Konfeksiyon Araştırma-Uygulama Merkezi Yayını.

Elmas, Ç. (2003). *Yapay sinir ağıları*. Ankara: Seçkin Yayıncılık.

Elmas, Ç. (2007). *Yapay zeka uygulamaları*. Ankara: Seçkin Yayıncılık.

Ertuğrul, S. ve Uçar, N. (2000). Predicting Bursting Strenght of Cotton Plain Knitted Fabrics Using Intelligent Techniques. *Textile Research Journal*, 70 (10), 845-851.

Golob, D., Osterman, D. P. ve Zupan, J. (2008). Determination of pigment combinations for textile printing using artificial neural networks. *Fibres & Textiles in Eastern Europe*, 16 (3), 93-98.

Jasper, W. J., Kovacs, E. T. ve Berkstresser, A. (1993). Using neural networks to predict dye concentrations in multiple-dye mixtures. *Textile Research Journal*, 63 (9), 545-551.

Mahlmann I., Hermanns, T., Veit, D. ve Gries, T. (2007). Prediction of processing behavior of PET staple fibers. *Melliand Textilberichte*, 88 (9), 114-116.

Neuron & Impulse & Synapse, (b.t). 11 Eylül 2009, http://www2.cedarcrest.edu/academic/bio/hale/bioT_EID/lectures/tetanus-neuron.html.

Oğulata, S. N., Şahin, C., Oğulata, R. T. ve Balcı, O. (2006). The prediction of elongation and recovery of woven bi-stretch fabric using artificial neural network and linear regression models. *Fibres & Textiles in Eastern Europe*, 14 (2), 46-49.

Öner, E. (2006). *Tekstil endüstrisinde renk ölçümü ve renk ölçüm bilimindeki son gelişmeler, seminer notları, Adana*.

Öztemel, E. (2003). *Yapay sinir ağıları*. İstanbul: Papatya Yayıncılık.

Radial Basis Function, (b.t). 12 Kasım 2009,
<http://www.hindawi.com/floats/129761/figures/129761.fig.012.jpg>.

Ratee, I. D. (1995). Chemistry of the textiles industry. C.M. Carr, (Ed.), *The colouring of textiles*. Cambridge: Blackie Academic & Professional.

Rys, P. ve Zollinger, H. (1975). The theory of coloration of textiles. C. L. Bird ve W. S. Boston (Ed.), *Reactive dye-fibre systems*. West Yorkshire: The Dyers Company Publications.

Senthilkumar, M. (2007). Modelling of CIELAB values in vinyl sulphone dye application using feed-forward neural networks. *Dyes and Pigments*, 75 (2), 356-361.

Senthilkumar, M. ve Selvakumar, N. (2006). Achieving expected depth of shade in reactive dye application using artificial neural network technique. *Dyes and Pigments*, 68, 89-94.

Westland, S. (1998). Artificial neural networks and colour recipe prediction. *Proceedings of the International Conference and Exhibition Colour Science-98*.

Westland, S., Lovine, L. ve Bishop, J. M. (2002). Kubelka-Munk or neural networks for computer colorant formulation. *9th Congress of the International Color Association, Proceedings of SPIE*, 4421, 745-748.

Yakartepe, M. ve Yakartepe, Z. (1995). *Tekstil terbiye teknolojisi, kasardan apreye*. İstanbul: Tekstil ve Konfeksiyon Araştırma Merkezi Yayını.

Yapay sinir ağları, (b.t). 15 Mayıs 2009,
http://tr.wikipedia.org/wiki/Yapay_sinir_a%C4%9Flar%C4%B1.

Yurdakul, A. ve Atav, R. (2006). *Boya-baskı esasları*. İzmir: Ege Üniversitesi Tekstil ve Konfeksiyon Araştırma-Uygulama Merkezi Yayını.

Yang, H., Zhu, S. ve Pan, N. (2010). On the Kubelka-Munk single constant/two constant theories. *Textile Research Journal*, 80 (3), 263-270.

Zayani, R., Bouallegue, R. ve Roviras, D. (28 Haziran 2008). *Adaptive predistortions based on neural networks associated with Levenberg-Marquardt Algorithm for satellite down links*. 10 Ağustos 2008, <http://www.hindawi.com/journals/wcn/2008/132729.fig9.html>.