



RENK REÇETESİ TAHMİNLENMESİNDE YAPAY SİNİR AĞLARININ KULLANIMI

Nurhan ONAR
Pamukkale Üniversitesi
Müh. Fak. Tekstil Müh. Böl.
20020 Kırıkkale/Denizli

ÖZET

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 boyacı uzmanları için bile zordur. Reçete tahmini; klasik reçete çıkarma sistemine göre veya bilgisayarlı reçete çıkarma sistemine göre yapılabilir. Klasik reçete çıkarma sisteminde bir boyacı 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 (yapay sinir ağları) modele dayanabilir. Bu makalede doğrusal olmayan sisteme dayanan yapay sinir ağlarının kullanımını ile reçete çıkarma sisteminin nasıl çalıştığı açıklanacaktır.

Anahtar Kelimeler: Renk reçetesi tahmini, K-M modeli, yapay sinir ağları

NEURAL NETWORKS MODEL ON COLOR RECIPE PREDICTION

ABSTRACT

Color recipe prediction was known to predict which colorants and their concentrations were required for a given reference color. Making a good color recipe prediction is even hard to expert colorists. Color recipe prediction can be made by classical and computerized recipe prediction systems. The classical system is based on a colorist's prediction, while the latter is applied as linear model (Kubelka-Munk model) in common or nonlinear model (such as neural network model). In this paper, how color recipe prediction by neural network based on nonlinear model is working was reviewed.

Keywords: Color recipe prediction, K-M model, neural networks

*Sorumlu Yazar/Corresponding Author: nonar@pau.edu.tr

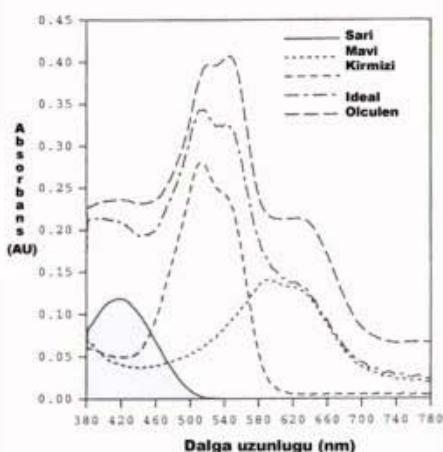
1. GİRİŞ

Genel bilgisayar ile boyarmadde konsantrasyon hesabı sistemleri Beer yasasına dayandırılmıştır. Beer yasasına göre konsantrasyon ve boyarmadde absorbansı arasında lineer bir ilişki vardır ve renk absorbsiyon ölçümü Kubelka-Munk denklemine (denklem 1) göre yapılmaktadır.

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

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

Bu esasa dayanan modellerde bir çözeltideki absorblayıcı türlerin karışımı için spektrumun, tek başına spektraların toplamına eşit olduğu tahmin edilir. Fakat boyarmaddelerin karışıntıları için bu tahmin yapılamaz. Aşağıdaki şekilde de görüldüğü gibi 3 absorbans spektralarının ideal olarak birbirine ilavesi deneyel olaraq ölçülen spektruma benzememektedir (Şekil 1)[1].



Şekil 1. Üçlü boyarmadde karışımının etkileri [1].

Cözeltideki boyarmadde karışımının spektrasi çözelti içindeki çeşitli heterojen etkileşimlerden dolayı boyarmaddelerin tek başlarına spektralarının toplamı değildir. Çözelti içindeki bu heterojen etkileşimler farklı boyarmadde büyülüklüklerine bağlı olarak değişen boyaboya ve boyaboyası etkileşimleri, çözelti sıcaklığına ve pH varyasyonlarına bağlı olarak boyarmadde absorbtivitelarındaki farklılıklar olarak sıralanabilir. Bu heterojen etkileşimler boyarmadde konsantrasyonu ve absorbansı arasındaki doğrusallığı bozar. Bu nedenle çoklu boyarmadde karışımında konsantrasyon tahmini için yeni bir lineer olmayan model geliştirilmesine ihtiyaç duyulmuştur. Bu amaçla yapay sinir ağlarının kullanımının iyi sonuçlar verdiği bulunmuştur [1]. Çünkü bu amaçla yapay sinir ağlarında kullanılan aktivasyon fonksiyonu doğrusal olmayan yapıya sahiptir.

Bununla birlikte bilgisayarlı reçete hesaplama sistemleri bir ön hazırlık işlemini gerektirir. Bu ön hazırlık işlemi zaman alıcı ve iş gücü gerektiren bir işlemidir. 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 [2]. Yapay 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 yapay sinir ağlarına dayanan sistemde reçete hesabında hata payı azalmaktadır.

Yapay sinir ağları renk reçete hesaplama sistemleri yanında renk uygulamalarında pek çok alanda başarıyla uygulanmıştır. Chung ve ark. renk analizinde RGB ve XYZ haritalarını oluşturmak için yapay sinir ağı modelini kullanmıştır [3]. Balcı ve Oğulata kimyasal bitim işlemleri sonucunda boyanmış kumaşlarda renk değişiminin ve CIELab değerlerinin belirlenmesi için yapay sinir ağlarını kullanmıştır [4]. Golob ve ark. tekstil baskı patı formulasyonlarının kombinasyonunu tespit etmek için yapay sinir ağlarını kullanmışlardır. Bu çalışmada istenen rengi elde etmede uygun boyaları saptamak için renk uzmanlarına yardımcı olarak yapay sinir ağlarının etkinliği gösterilmiştir [5]. Furferi ve Carfagni jiggerde boyanan selüloz esaslı kumaşların renginin ve renk stabilitesinin tahminlenmesi için yapay sinir ağlarını kullanmışlardır. Jiggerde boyanan bir kumaşın rengi ve renk stabilitesi boyaların rengine, işlem sıcaklığına, boyabanyosunun pH'sına ve boyama süresi gibi teknolojik parametrelerle büyük ölçüde bağlıdır. Renk uzmanları istenen rengi ve reçeteyi tutturmak için pek çok test yapmak zorundadır. Bu çalışma renk uzmanının boyama testlerine ihtiyaç duymaksızın rengi ve renk stabilitesini tahmin etmesine yardımcı olmayı amaçlamıştır [6]. Li ve ark. radyal temelli fonksiyon ile yapay sinir ağları ve genetik algoritma kullanarak bir renk karşılaştırma yöntemi geliştirmiştirlerdir. Tekstil laboratuvar değerleri ve boyabanyosunları arasında lineer olmayan bir ilişkinin olduğu gösterilerek yapay sinir ağında boyabanyosun girdi değeri ve teknik laboratuvar değeri çıktı değeri olarak alınmıştır. Renk karşılaştırmasının optimal formülünü bulmak için genetik algoritma da modele dahil edilmiştir. Kubelka-Munk teorisi ile renk karşılaştırmasına göre bu modelin yüksek kesinlik, düşük ücret ve hızlı cevap alma gibi bazı avantajlara sahip olduğu bulunmuştur Denemeler göstermiştir ki bu model kullanıcıya hızlı bir şekilde tatmin edici bir formül sağlayabilir [7].

Vadood ve ark. yapay sinir ağları ve genetik algoritmayı kullanarak akrilik kuru çekim üretim hattının optimizasyonunu sağlamaya çalışmışlardır [8]. Nasiri ve ark. poliester boyamada istatistiksel regresyon, bulanık regresyon ve yapay sinir ağı modelleme metotlarını karşılaştırmışlardır [9]. Xu ve Lin bulanık-sinir sistemlerini kullanarak baskılı kumaşların otomatik renk analizini çalışmışlardır [10]. Thevenet ve ark. ileri besleme yapay sinir ağlarını kullanarak iplik eğirme işleminden sonra renk değişimlerini modellemişlerdir [11]. Trussell renk hesaplaması için yapay sinir ağlarını, bulanık mantık ve dijital sinyal işleme proseslerini uygulamıştır [12]. Lin ve ark. tekstil moda renk trendini tahminlemek için bir gri yapay sinir ağı modeli geliştirmiştir [13].

2. YAPAY SINİR AĞLARI

Yapay sinir ağlarına dayalı modeller yapay zeka kavramına dayanarak türetilmişlerdir. Yapay zekanın tanımı tartışmalı bir kavramdır. Coğu araştırmacının kabul ettiği gibi yapay zeka alanında iki ana hedef vardır. İlk ve onde gelen hedef zeki makineler üretmektir. İkinci hedef ise zekanın yapısını keşfetmektir. Zekanın yapısı araştırılırken bu yönde eğilimlerden biri beynin modellenmesi yönüne kaymıştır. Beynin modelleri nöronlar ve yapay sinir ağları baz alınarak üretilmiştir ve bu nöronlar ve yapay sinir ağları bilgi işleme için kullanılmıştır.

Bugün yapay sinir ağlarının kullanımı üzerine çok fazla sayıda araştırma vardır ve yapay sinir ağlarının özellikle konuşma tanıma ve makinenin görme gücü kazanması alanlarında başarılı kullanımı bu uygulamaların yaygınlaşmasını cesaretlendirmiştir [14].

Wu ve ark. iplik eğirme sistemlerinde geri yayılma yapay sinir ağları ve bulanık kontrol yapay sinir ağları olmak üzere iki farklı yapay sinir ağı modelini kullanmışlardır. Bu iki modelin yüksek kalite tahminlemesi sağladığı ve bulanık kontrol sistemi ile elde edilen sonuçların öğrenme prosesini önemli miktarda hızlandırma potansiyeline sahip olduğu bulunmuştur [15]. Yin ve ark. yağ lekesi, delik gibi tekstil hatalarının sınıflandırılmasında geri yayılma yapay sinir ağlarını kullanmışlar ve bu yöntemin etkili bir şekilde hataları tespit edebildiğini ve yüksek tanıma doğruluk oranında hata tiplerini sınıflandırdığını bulmuşlardır [16, 17]. Liu ve ark. teknik liflerinin kantitatif analizi için geri yayılma yapay sinir ağları esasına dayanan Yakın Kızılıtesi Spektroskopisinin kullanımını önermişlerdir [18]. Kumar ileri besleme yapay sinir ağları sistemini kullanarak bölgesel teknik liflerinin ayrılması için yeni bir yaklaşım geliştirmiştir. Aynı zamanda lineer yapay sinir ağlarını kullanarak hızlı ağ analizi için yeni düşük ücretli bir çözüm önermişlerdir. Önerilen bu iki yaklaşım ile gerçek kumaş hatalarından elde edilen deneysel sonuçların faydalı olduklarını doğrulamışlardır [19]. Su ve ark. teknik tekstüre tiplerini tanıtmak için geri-yayılma

yapay sinir ağı bulanık kümelendirme analizi kullanımını ve görüntü renk tonu ve değerlerini elde etmek için *wavelet transfer* kullanımını önermişlerdir [20]. Bir çalışmada dijital kamera ile alınan dijital kumaş görüntülerini yapay sinir ağlarına beslemek için ve RGB görüntülerinin dönüşümleri için ilk olarak bölgesel eşik teknikleri ve restorasyon prosesi ile ikili görüntülere dönüştürülmüştür. Daha sonra hataların alanı, bir görüntüdeki nesne sayısı ve şekil faktörü olmak üzere 3 farklı özellik yapay sinir ağlarının gerçek girdisi olarak belirlenmiştir. Bu sistemin çok yaygın hataları ve az görünen hataları teşhis edebildiği bulunmuştur [21]. Wu ve ark. yapay sinir ağları için "Elektromanyetik Algoritma" olarak isimlendirilen heuristik algoritmayı kullanarak konfeksiyon perakende işlemlerinin anahtar girdileri ve performans ölçümü arasındaki ilişkinin meta-modelini geliştirmiştir [22]. Bhattacharjee ve Kothari kumaşların ıslı dayanımını ölçmek için ileri-besleme, geri yayılma yapay sinir ağı sistemini kullanmıştır [23]. Yuen ve ark. örme kumaşlarda dikiş hatalarının sınıflandırılması için geri yayılma ve radyal esaslı yapay sinir ağı sisteminin kullanımının etkili olduğu bulmuştur [24]. Bir çalışmada fonksiyonel teknik dizayn sistemlerinde giysilerin ıslı fonksiyonunu tahminlemek için bölgesel ve toplam ıslı hassasiyet modellerine dayanan bulanık yapay sinir ağ sistemi sunulmuştur. Daha önce çalışılan deneysel ve regresyon analiz yaklaşımlarına benzemeyerek bu model insan ıslı cevabı-vücutözü ve cilt sıcaklığı gibi direk faktörlere bağlıdır [25]. Hadizadeh ve ark. bir çalışmalarında bezayağı dokuma ve bezayağı dokuma türevi kumaşların yük-uzama davranışını tahminlemek için yapay sinir ağlarını kullanmışlardır [26]. Yu ve ark. teknik atık sularından renk uzaklaşması için oksidasyon azalma potansiyelini (ORP) monitörleme ve yapay sinir ağlarını kullanarak bir Fenton dozaj kontrol stratejisini kurmuşlardır [27]. Chen ve ark. proses parametrelerinden spundond dokusuz yüzeylerin lif çapını tahminlemek için istatistiksel ve yapay sinir ağı modellerini kullanmışlardır. Bayesian çerçevesinin yapay sinir ağı daha küçük tahminleme hatası üretmiştir [28]. Chen ve ark. kamgarn kumaşların makaslama sertliğinin tahminlenmesi için yapay sinir ağlarını kullanarak girdi değişken seçim metodunu önermişlerdir [29]. Bo, yapay sinir ağı teorisini kullanarak hasıllı iplik kalitesine göre dokumada çözgü kopuş oranlarını tahminlemiştir. Sonuçlara göre yapay sinir ağlarının kalite tahminlemesi için etkin bir teknik olduğu ve teknik endüstrisinde pek çok alanda kullanılabileceği bulunmuştur [30]. Nateri ve ark. nanobitim görmüş pamuklu kumaşın antibakteriyal aktivitesini yapay sinir ağı akıllı sistemini ve bulanık-sinir teknığını kullanarak simüle etmişlerdir [31]. Au ve ark. hata geri-yayılma öğrenme algoritması ve bulanık analitik hiyerarşi prosesi ile ileri besleme yapay sinir ağı kullanarak bir konfeksiyon fabrikasının yerleşimini belirlemek için karar alma modeli geliştirmiştir [32]. Chen ve Huang kumaş boncuklanma derecelerinin değerlendirilmesi için objektif

ve yenilikçi bir araç olarak görüntü analizini kullanmışlar ve yapay sinir ağlarının Kohonen kendi kendine organize görüntü haritaları ile boyanma derecesini değerlendirmiştir [33]. Bu çalışmalara benzer şekilde kumaş hatalarının analizinde [34, 35, 36, 37], ipliklerin özelliklerinin tahminlenmesinde [38, 39, 40], hayvansal liflerin teşhis ve sınıflandırılmasında [41, 42, 43], filtrasyonda kullanım için nonwoven kumaşların yapıözellik ilişkilerinin modellenmesinde [44], tekstil proseslerinin entegrasyonu ve kontrolünde [45, 46, 47], buruşmuş kumaşların görsel özelliklerini değerlendirmek için [48], dokusuz yüzeylerin yapısal parametrelerinin tasarılanmasında [49], moda perakende tahminlenmesinde [50], iplik çekmesinin tahminlenmesinde [51] ve liflerin çekilebilirliğinin tahminlenmesinde [52] yapay sinir ağlarının kullanımına çalışılmıştır.

Reçete tahmininde kullanılan yapay sinir ağları bir girdi ve çıktı tabakasından ve bir veya birkaç gizlenen tabakadan oluşmaktadır. Yapay sinir ağları gizlenen tabaka kullanıldığında tek tabaka algılama sistemi (single layer perceptron, SLP), gizlenen tabaka kullanıldığında ise çoklu tabaka algılama sistemi (multilayer perceptron, MLP) olarak adlandırılır. Şekil 2 ve denklem 2'ye göre bir toplam ve bu toplamın aktivasyon fonksiyonuna yerleştirilmesi ile çıktı tabakası nöronları hesaplanır.

$$a = \sum_{j=0}^n w_j x_j \quad (2)$$

Burada w_j ; ağırlıkları, x_j ; ise girdi tabakasındaki nöronların değerlerini gösterir. j ; ise girdi tabakasındaki nöronları ifade eden bir alt indistir.

Reçete tahmininde kullanılan yapay sinir ağı modellerinde genellikle aktivasyon fonksiyonu olarak nonlinear bir yapı gösteren sigmoid fonksiyonu (denklem 3) kullanılır.

$$O=F(a)=1/(1+e^{-a}) \quad (3)$$

Burada, $F(a)$; aktivasyon fonksiyonu ve a ; nöronların ağırlıklarıyla çarpımının toplamı (bias değeri bu toplamdan çıkarılır) olarak ifade edilmiştir.

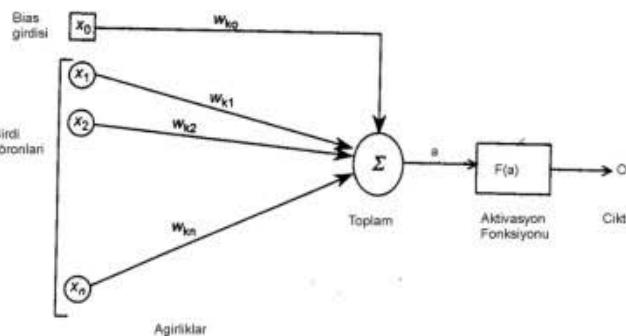
Bu sigmoid fonksiyonu ile boyarmaddelerin konsantrasyonları ağırlıklara bağlı olarak hesaplanabilir. Arada gizlenen tabaka var ise önce gizlenen tabakanın nöronlarının değerleri denklem 4'e göre ve sonrasında çıktı tabakasındaki nöronların değerleri denklem 5'e göre hesaplanır.

$$H=F_H(IW_H-\theta_H) \quad (4)$$

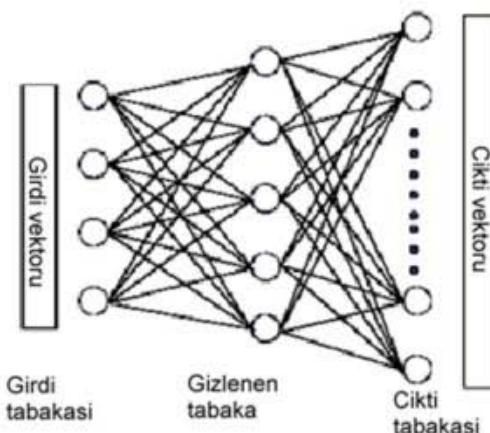
$$O=F_O(HW_O-\theta_O) \quad (5)$$

Burada, H ; gizlenen tabaka nöronları, O ; çıktı nöronları, F_H ; aktivasyon fonksiyonu, I ; girdi nöronları, H ; gizlenen tabaka nöronları, W_H ve W_O ; gizlenen tabaka ve çıkış tabakası ağırlıkları, θ_H ve θ_O ; gizlenen tabaka ve çıkış tabakası bias değerleri.

Bu nöronlar matriks yapısında elde edilebilir. Örneğin [1, 5, 1, 5, 0, 5] çıktı matriksi 3 boyarmadde konsantrasyonunu vermektedir.



Şekil 2. Tek tabaka algısal yapay sinir ağı [53]



Şekil 3. Çoklu tabaka algısal yapay sinir ağı [2]

Girdi ve çıktı tabakalarının boyutları problem tarafından saptanmasına rağmen verilen herhangi bir problemi çözmek için istenen gizlenen tabakadaki nöron sayısı yalnızca deneyel olarak saptanabilir. Ayrıca transfer (aktivasyon) fonksiyonu, öğrenme hızı, öğrenme kuralı (ağırlıkların değişimi için), ve istenen öğrenme örneklerinin sayısının seçimi tümyle deneyel olarak saptanmalıdır.

Pek çok çeşit sinirsel hesaplama metodu bulunurken, burada kullanılan yapay sinir ağı modeli çeşidi sınıflandırma modellerini (perceptron) oluşturur. Bir renk uzmanının örnek bir rengi kırmızımsı yeşil (kırmızısı çok) olarak sınıflandırması gibi, bu yapay sinir ağı modeli de öğrenme ve deneyim kazanma aşamasından sonra Kubelka-Munk modelinde absorbtivitelerde denk gelen ağırlıkları nonlinear olarak değiştirerek (örneğin mavinin ağırlığını sıfırlayarak ve yeşilden çok kırmızıya ağırlık vererek) bu rengi sınıflandırabilmektedir. Reçete tahminlemesi durumunda girdi tabakası nöronlarını renk koordinatları (CIELab değerleri, XYZ değerleri), L^* , a^* ve b^* değerleri ve spektral radyans faktörü (SRF) ve spektral reflektans değerleri [54, 14, 55] ve çıktı tabakası nöronlarını ise boyarmadde konsantrasyonları oluşturabilir.

Ayrıca burada dikkat edilmesi gereken bir husus da şudur ki; renk tahminlemesi ve reçete tahminlemesi farklı kavramlardır. Renk tahminlemesinde bir reçeteden üretilen rengin spektral reflektans değerlerinin tahminlemesi gerçekleştirilir. Reçete tahmininde ise bunun tam tersi bir işlem uygulanır, yani alınan bir rengin spektral reflektans değerlerinden reçete tahmini, dolayısıyla karışım boyarmaddelerinin konsantrasyonlarının tahmini gerçekleştirilir. Pratikte bu iki sınıf parametre arasında tam ters bir ilişki yoktur ve tersine işleyen problemi çözmek kolay değildir. Yani hedef; reflektans spektrumu verildikten sonra renk-lendirici reçetesinin tahmin edilmesidir [2].

Yapay sinir ağlarında örnekler öğrenme kümesi ve test kümesine ayrılır. Öğrenme kümesi kullanılarak öncelikle yapay sinir ağı öğretilir. Öğrenme periyodunda renk girdileri (renk reflektans değerleri gibi) ve karışım boyarmadde konsantrasyonları (çıktılar) arasındaki ilişkiyi yapay sinir ağı öğrenir. Öğrenme periyodu boyunca ağa pek çok örnek verilir. Üretimden gelen boyanmış örnekler bu görev için yani ağı öğrenmesi için idealdir. Ağı öğrenmesi sırasında reçete (çıktı) ve renk reflektans değerleri (girdi) bilinir. Böylece ağı oluşturan yapay nöronlar arasındaki bağlantıların ağırlığı ayarlanarak basit bir şekilde ağı bu bilgiyi depolar. Öğrenmenin depolama işlemi boyanmanın bilgi ve deneyimlerini biriktirme işine benzerdir [2]. Daha sonra test örnekleri kullanılarak ağıın ve belirlenen ağırlıkların doğruluğu test edilir.

Bir kere uygun olarak öğretilen ağı; ağıın test örneklerinde çıktı nöronlarını kendisi hesaplayabilir. Bu "genelleştirme" olarak bilinen önemli bir özellikleştir.

Bir yapay sinir ağını tasarlama en önemli parametreler kaç gizlenen tabaka ve gizlenen tabakada kaç gizlenen nöron kullanılacağı ve öğrenme kümesinin büyüklüğüdür. Gizlenen nöron sayısı deneysel olarak saptanır. Gizlenen nöron sayısına karşı test performansı eğrisi çıkarılır ve en yüksek performans sağlanan gizlenen nöron sayısı tercih edilir.

Ağırlıkların belirlenmesinde momentum terimi ile uygun ağırlık değerlerine daha hızlı yakınsama sağlanır. Momentum terimi 0-1 arasında bir değerdir [56].

3. RENK ÖLÇÜMÜNDE SİNİR AĞLARININ KULLANIMI ÜZERİNE ÇALIŞMALAR

Bishop (1991), normalize edilmiş tristimulus değerlerine dayanan bir yaklaşımı simüle etmek için geri yayılma ağını (backpropagation net, BPN) kullanmıştır. Bu yaklaşının avantajı tristimulus değerleri ile girdi değişkeninin sayısının 3 ile sınırlanmasıdır. Bu durumda bu ağı topolojisi çok basittir: 3 girdi, 8 ve 16 gizlenen ve renk sayısı kadar çıktı nöron birimlerinden oluşur. Fakat sonuçların pratik ile uyumu çok düşüktür [57].

Jasper ve ark. (1993); 3 ticari boyarmadde kullanarak (Cibacron yellow G-E, Cibacron brilliant red 4G-E, ve

Cibacron blue TR-E) 0, 0.05, 0.1 ve 0.15 g/l konsantrasyonlarda toplam 62 tane olmak üzere tekli, ikili ve üçlü boyarmadde karışımı ile boyama reçeteleri üretmiştir. 3 farklı model ile boyama reçeteleri elde edilmiştir: Beer yasası modeli (Model I), modifiye lineer model (Model II) ve yapay sinir ağı modeli (Model III). Beer yasasına göre boyarmaddelerin maksimum absorbasyon yaptıkları dalga boyundaki absorbans değerleri ve konsantrasyon arasındaki ilişki denklem 6'de gösterildi.

$$A = alc \quad (6)$$

Burada, A; boyarmaddenin maksimum absorbasyon yaptığı dalgalaboyunda absorbans değeri, a; boyarmaddeye özel absorbtivite katsayıları; l; ışığın geçtiği yol uzunluğu ve c; boyarmadde konsantrasyonunu ifade etmektedir.

Reçete tahminlemesindeki relativ yüzde hatalar tek boyarmadde ile boyamalar için denklem 7'ye göre hesaplanmıştır. Çoklu boyarmadde karışımı ile boyamalar için reçete tahminlemesindeki relativ yüzde hatalar ise denklem 8'e göre hesaplanmıştır.

$$\%Hata = \left| \frac{c_{gercek} - c_{tahminlenen}}{c_{gercek}} \right| \times 100 \quad (7)$$

$$\%Hata = \sqrt{\frac{(R_{gercek} - R_{tahminlenen})^2 + (B_{gercek} - B_{tahminlenen})^2 + (Y_{gercek} - Y_{tahminlenen})^2}{R_{gercek}^2 + B_{gercek}^2 + Y_{gercek}^2}} \times 100 \quad (8)$$

Burada; c; konsantrasyonun, R; kırmızı boyarmadde konsantrasyonunun, B; mavi boyarmadde konsantrasyonunun; Y; sarı boyarmadde konsantrasyonunun alt indise bağlı olarak gerçek ve tahminlenen değerlerini ifade etmektedir.

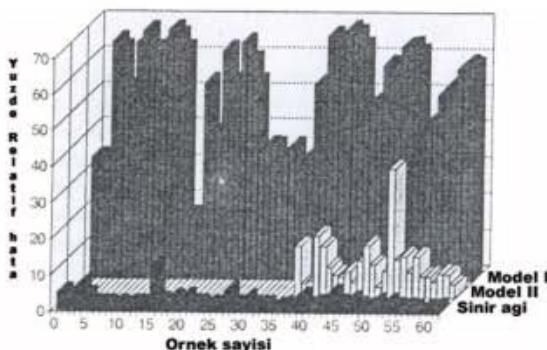
Beer yasası modeli (Model I) için denklem 9'deki matematiksel ifade; modifiye lineer model (Model II) için denklem 10'deki matematiksel ifade kullanılmıştır.

$$\begin{bmatrix} A_{520} \\ A_{595} \\ A_{420} \end{bmatrix} = \begin{bmatrix} CC_{11} & CC_{12} & CC_{13} \\ CC_{21} & CC_{22} & CC_{23} \\ CC_{31} & CC_{32} & CC_{33} \end{bmatrix} \begin{bmatrix} c_1 \\ c_2 \\ c_3 \end{bmatrix} \quad (9)$$

$$\begin{bmatrix} A_{520} \\ A_{595} \\ A_{420} \\ A_{480} \end{bmatrix} = \begin{bmatrix} \beta_{01} & \beta_{11} & \beta_{12} & \beta_{13} \\ \beta_{02} & \beta_{21} & \beta_{22} & \beta_{23} \\ \beta_{03} & \beta_{31} & \beta_{32} & \beta_{33} \\ \beta_{04} & \beta_{41} & \beta_{42} & \beta_{43} \end{bmatrix} \begin{bmatrix} 1 \\ c_1 \\ c_2 \\ c_3 \end{bmatrix} \quad (10)$$

Burada A; boyarmaddelerin maksimum absorbasyon yaptıkları dalga boyları olan 420 nm'de sarı, 595 nm'de mavi, 520 nm'de kırmızı boyarmadde için absorbans değerlerini, $C_{ij} = a_{ij}l$; tek başına boyarmaddelerin spektrasından elde edilen kalibrasyon katsayıları, β_{ij} ; ise Model II için kalibrasyon katsayılarını; c_1, c_2, c_3 ; sırasıyla kırmızı, mavi ve sarı boyarmaddelerin konsantrasyonunu ifade etmektedir.

Model II'de β_{ij} ; kesişim terimidir ve bu terim ile üçlü boyarmadde karışımındaki boyarmadde etkileşimleri hesaba katılabilmiştir. Ayrıca bu modelde 4 dalgaboyu için absorbans değerleri kullanılmıştır.

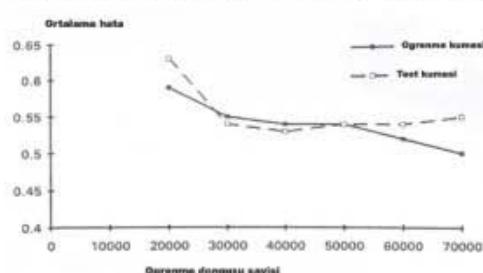


Şekil 4. Üç model için yüzde relatif hataların histogramı [1].

Yapay sinirsel ağ modelinde geri yayılma yaklaşımı (back propagation net, BPN) kullanılmıştır. Aktivasyon fonksiyonu olarak sigmoid fonksiyon, Aspirin isimli bir software, farklı ağ topolojileri (en iyi sonuç 401-12-3 ile elde edildi) denenmiştir. 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 karışımı için %9 ortalama relatif hata vermiştir. Model III %2,6 relatif hata ile diğer modellerin tümünden iyi sonuç vermiştir [1].

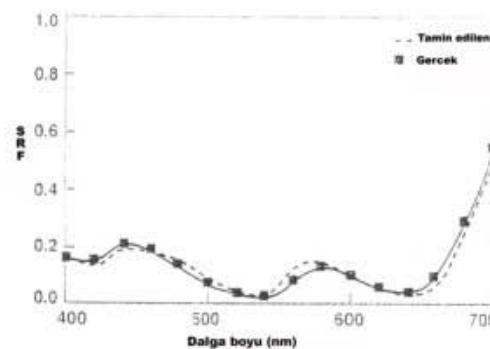
Bu çalışmaya Vangheluwe ve ark.'ları (1994) tarafından yapılan bir eleştiride networkun öğrendiğini doğrulamak için herhangi bir test kümesi bulundurulmadığı bildirilmiştir [58]. Buna karşılık olarak Jasper (1994) test örnekleri kullandıklarını açıklamıştır. Fakat test kümesi olarak kullanılan örnek sayısı hala açık olarak belirtilmemiştir.

Şekil 5'te de gösterildiği gibi belirli bir değerden sonra öğrenme döngüsü (kümesi) sayılarındaki artış öğrenme kümesinin doğruluğunu artırırken, test kümesinin doğruluğunu azaltmaktadır. Bu aşırı öğrenme (over training) denilen durumdan kaçınmak için öğrenme ve test kümesi örnek sayılarının doğru seçilmesi önemlidir. Aşırı öğrenme; öğrenme kümesinin belirli bir örnek sayısından sonra yapay sinir ağının ağırlık düzeltmesi ile hatayı azaltması yerine ezberlemeye başlaması ve dolayısıyla hata payının artmaya başlamasına yol açmaktadır [59].

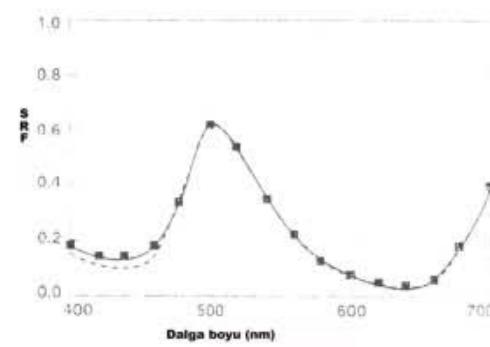


Şekil 5. Öğrenme kümelerindeki döngü sayılarına göre öğrenme kümeleri ve test kümelerindeki ortalama hatalar [8]

Bezzera ve Hawkyard (2000) çalışmalarında 3 farklı ileri besleme yapay sinir ağı (feedforward neural network) yöntemini floresant boyarmaddelerin konsantrasyonunu tahmin etmek için kullanmışlardır. 283 örnek yapay sinir ağının öğrenmesi için ve 28 örnek yapay sinir ağını test etmek için kullanılmıştır. Bu yöntemde girdi tabakası nöronları olarak toplam spektral radyans faktörü (SRF), XYZ ve L*a*b* değerlerinden faydalanılmıştır. Bu girdileri farklı olan yapay sinir ağlarından yalnızca SRF değerlerini girdi nöronu olarak kullanan yapay sinir ağı %3,92 ortalama yüzde relatif hata ile kabul edilebilir sonuç vermiştir. XYZ ve L*a*b* girdi nöronları için yapay sinir ağları ise sırasıyla %45,66 ve %39,48 ortalama yüzde relatif hata değeri vermişlerdir. Aynı zamanda tersine yönde işlem uygulandığında yani konsantrasyon değerlerinden SRF eğrilerinin üretilmesinde iyi sonuçlar elde edilmiştir. Ayrıca test kümelerindeki örnek sayısının 189'dan (%3,56 rölatif hata) 208'e (%4,43 rölatif hata) artırılması ile 400-700 nm arasında tahmin edilen ve ölçülen SRF değerlerinden oluşan eğriler çıkarılmıştır (Şekil 6, 7) [54].



Şekil 6. 189 örnek sayısı için gerçek ve tahmin edilen SRF eğrileri [53]



Şekil 7. 208 örnek sayısı için gerçek ve tahmin edilen SRF eğrileri [53]

Marjoniemi ve Mantysalo (1997); ANFIS (Adaptive Neuro Fuzzy Inference System) sistemini; dalga boyu ve konsantrasyondan boyarmadde absorbansını tahmin etmek için kullanmayı denemişlerdir. 2 veri kümesi ve ikili boyarmadde karışımının her biri bu amaç için kullanılmıştır. Birinci veri kümesinde sari boyarmaddenin konsantrasyonu 50 mg/l, ikinci veri kümesinde 100 mg/l olarak alınmıştır. Kırmızı boyarmaddenin konsantrasyonu ise birinci ve ikinci veri kümesinde 0-900 mg/l aralığında değişmiştir

ve her bir veri kümesi için 18 düzeye ayarlanmıştır. 400-580 nm dalga boyu arasında 19 dalga boyu düzeyi kullanılmıştır. Öğrenme kümesi 342 örnekten, test kümesi 23 örnekten oluşmuştur. Kırmızı boyarmadde konsantrasyonunda değişimlerle görünür bölgedeki gerçek ve tahmin edilen absorbans değerleri arasında uyum gözlenecek ANFIS'in başarısı kanıtlanmıştır.

Yapay sinir ağının performansına denklem 11'den elde edilen standart tahminleme hatasına (P) göre karar verilmiştir.

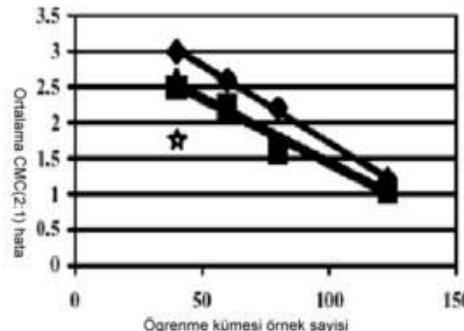
$$P = \left(\sum_{i=1}^n \left(\frac{c_{i,p} - c_i}{n} \right)^2 \right)^{\frac{1}{2}} \quad (11)$$

Burada $c_{i,p}$; örnek i için test kümesinin tahmin edilen ortalama konsantrasyonu, c_i ; örnek i için test kümesinin bilinen konsantrasyonu, n ; test örneklerinin sayısını ifade etmektedir [60].

Westland (1998); çoklu tabaka algısal yapay sinir ağını (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 karışıntıları opak grafik üzerine basılmıştır. 123 örnekten oluşan öğrenme kümesi ve 40 örnekten oluşan test kümesi olmak üzere 163 renk örneği kullanılmıştır. Diğer ağlarda 80, 60 ve 40 öğrenme kümesi örnek sayısı kullanılarak öğrenme kümesi örnek sayısının yapay sinir ağlarının tahminleme performansındaki etkisi incelenmiştir.

Şekil 8'de aynı sayıda test örneği sayısı için renk tahminlemesinde yapay sinir ağının K-M modeli ile karşılaştırılmıştır. Yapay sinir ağının 6 (eşkenar dörtgen), 7 (kare) ve 8 (üçgen) gizlenen tabaka nöron sayısı ile çalışılmıştır. Şekil 8'de K-M modelinin performansı tek bir yıldız işaretile gösterilmiştir. Test kümesindeki her örnek için CMC(2:1) renk farklılığı hesaplanmış ve tüm örnekler için ortalama renk farklılığı belirlenmiştir. Verinin üç kümesinin her biri için kesiksiz çizgiler lineer regresyon uyumunu gösterir. Yapay sinir ağları performansında gizlenen tabakadaki nöron sayısının etkisinin az olduğu bulunmuştur. Öğrenme kümesindeki örnek sayısı artarken yapay sinir ağının performansında sürekli bir gelişme gözlenmiştir. Öğrenme kümesi örnek sayısı 123 olduğunda K-M modeli yaklaşık 1,5 birim ortalama E renk farklılığı verirken yapay sinir ağının kullanıldığında yaklaşık 1 birim ortalama E renk farklılığı elde edilmiştir. Ayrıca şekil 8'e göre 40 kalibrasyon örneği için K-M modelinin tercih edilir olduğu bulunmuştur. Fakat K-M modeline daha fazla örnek girilirse bunun modelin performansında daha fazla gelişme sağlayıp sağlanmayacağı açık değildir. Ayrıca yüksek sayıda

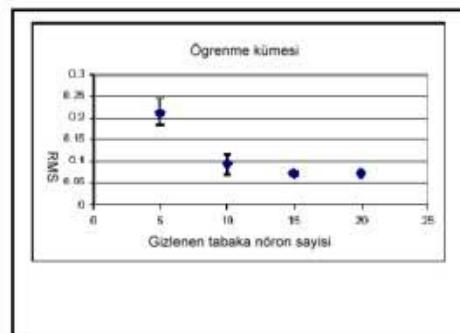
öğrenme kümesi örnek sayısı için ANN modeli oldukça uygunken, K-M denklemelerine ilave örnekler eklemek kolay değildir. ANN modeline ise 123'ten daha fazla örnek girmiş olsaydı olası olarak ΔE renk farklılığı değerlerinde daha fazla gelişme gözlenebileceği ve bu değerin 1'den aşağı düşeceği bildirilmiştir [2].



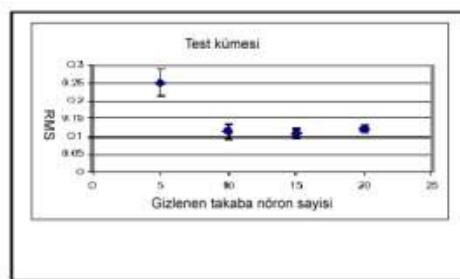
Şekil 8. Yapay sinir ağının K-M modeli ile karşılaştırılmış renk farklılığı [2].

Ayrıca Westland (2002); reçete tahminlemesinin tersine renklendirici konsantrasyonlarından spektral reflektansı tahminleme yeteneği bakımından Kubelka-Munk modeli ve yapay sinir ağlarını (ANN) kullanmıştır. Bunun için iki yöntemi kombine ederek hibrid bir KM-ANN modelinin performansını değerlendirmiştir. Bu amaç için, 6 mürekkep bileşeni (6 girdi tabakası nöronu) (açık reçine, beyaz, siyah, siyan, magenta ve sarı) kullanılmıştır. 108 renk reçetesi hazırlanmış ve basılmıştır. Her örneğin spektral reflektans değerleri ticari reflektans spektrofotometresi kullanarak 10 nm aralıklarla 400-700 nm bölgesinde ölçülmüş ve dolayısıyla 31 çıktı nöronu elde edilmiştir. 75 örnekten oluşan öğrenme kümesi ve ağın performansı belirlemek için 33 test kümesi örneği kullanılmıştır. Tahminleme performansı; gerçek ve tahminlenen spektralar arasında RMS (root-mean squares) hatası ve CIELab ΔE renk farklılığı hesaplamaları kullanarak belirlenmiştir. Yapay sinir ağının momentum ile BPN algoritması kullanarak öğretilmiştir. Bu algoritma (Matlab'da traingdm öğrenme (training) fonksiyonu ile) 2 parametreyi gerektirir: öğrenme hızı ve momentum terimi. Momentum terimi 0,9 olarak ve öğrenme hızı 0,2 olarak sabit alınmıştır. Yapay sinir ağları her biri için 500.000 toplam devir ile 5, 10, 15 ve 20 nöronundan oluşan gizlenen tabakalar kullanılmıştır. Gizlenen tabakadaki nöronlar için Tan-Sigmoid transfer fonksiyonu ve çıktı tabakası için Log-Sigmoid transfer fonksiyonu seçilmiştir.

Öğrenme kümesi için hata beklendiği gibi gizlenen tabakadaki nöronların sayısının artışı ile azalmıştır. Yapay sinir ağının genelleştirme yeteneğinin; öğrenme boyunca kullanılmayan ayrı bir veri kümesi (test kümesi) tarafından test edilmesi nedeniyle gizlenen nöronların sayısı 10'u aşındırında test kümesindeki hatanın artmaya başladığı görülmüştür (Şekil 9, 10).



Şekil 9. Öğrenme kümesi için RMS hatası [61].



Şekil 10. Test kümesi için RMS hatası [61].

ΔE renk farklılığı değerine göre yapay sinir ağlarının performansı karşılaştırıldığında, K-M modeli için 2,9; ANN için 8,23 ΔE renk farklılığı değeri elde edilmiştir. Fakat K-M modelinin bazı temel özellikleri sürdürülerek ANN esaslı bir hibrid model kullanıldığında, bu hibrid modelin ANN ve KM yaklaşımının her ikisinden üstün performans gösterdiği bulunmuştur [61].

Bunun ilerisinde yapılan çalışmalarda ise yapay sinirsel ağlar, bulanık sistemler ve genetik algoritma gibi çeşitli "soft computing" teknikleri kombine edilmiştir. Bu kombinasyon ile 0,27 gibi kabul edilebilir renk farklılık değerleri elde edilebilmiştir. Bu kombinasyonların açıklanması başka bir makalenin konusu olabilir. Bu modelin renk farklılığı değerlerini geliştirmesinin arkasında yatan mantık ise; renk reflektans değerleri yanında L, C, H gibi rengin algısal özelliklerinin (açıklık, renk tonu ve kroma) deksantrasyon hesabına katılmasıdır. Bu amaçla Mizutani ve ark. (1995, 2000) bu alanda çalışma yapmışlar ve CANFIS (Coactive neuro-fuzzy system) sistemi ve GNF (Genetic-Neuro-Fuzzy) sistemlerini kullanmışlar ve sırasıyla 2,0 ve 0,27 renk farklılık değerleri elde etmişlerdir [55, 62].

4. SONUÇ

Reçete tahminlemesinde Beer yasasına dayanan bilgisayarlı reçete hesaplama sistemleri yetersiz kalmaktadır ve tahminlenen ve gerçek reçete değerleri arasındaki hata yüzdesi çok yüksektir. Bu nedenle bilgisayarlı reçete hesabı için yeni modeller geliştirilmeye çalışılmaktadır. İnsan gözü 1,0 'dan daha küçük renk farklılıklarını ayırt edemez. Dolayısıyla endüstride ΔE renk farklılığı değerle-

rinin 1'den küçük olması istenir. Bu yüksek spesifik değerin karşılanması deneyimli renk uzmanları için bile zordur. Yeni geliştirilen yapay sinir ağlarına dayanan model ile hesaplanan reçetelerden elde edilen renk farklılık değerleri, geleneksel reçete ölçüm sistemlerine göre daha iyi renk farklılık değerleri vermesine karşın, bu yüksek spesifikasyonları tam olarak karşılayamamıştır. Yapay sinir ağı modelinde; Beer yasasına dayanan modele göre konsantrasyon ve absorbans arasındaki doğrusallığı bozan heterojen etkileşimler de hesaba katılmıştır ve bu da, modelin sonuçlarının gelişmesini sağlamıştır. Dolayısıyla yapay sinir ağlarının ve daha ilerisi için genetik algoritma, bulanık mantık ve bunların kombinasyonunun renk reçete tahminlenmesinde uygulanabilirliği hakkında daha detaylı çalışmalar yapılması önerilebilir.

KAYNAKLAR

- Jasper, W.J., Kovacs, E. T., Berkstresser, A. (1993) *Using Neural Networks to Predict Dye Concentrations in Multiple-Dye Mixtures*. Textile Research Journal, 63(9), pp. 545-551
- Westland, S. (1998), *Artificial Neural Networks and Colour Recipe Prediction*. Proceedings of the International Conference and Exhibition Colour Science-98
- Chung, B., Cho, C.-S., Park, M.-J. (2004) *Color inspection of printed texture using scanner: Compensation of positional deviation via NN model*, 8th International Conference on Control, Automation, Robotics and Vision, Vol.3, pp. 1826-1831
- Balcı, O., Oğulata, R.T. (2009) *Boyanmış Kumaşlarda Kimyasal Apre Uygulamaları Sonucunda Oluşabilecek Renk Değişiminin ve CIELab Değerlerinin Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi*, Tekstil ve Konfeksiyon, Vol. 1, pp. 61-69
- Golob, D., Osterman, D.P., Zupan, J. (July/September 2008) *Determination of Pigment Combinations for Textile Printing Using Artificial Neural Networks*, Fibers and Textiles in Eastern Europe, Vol. 16, No. 3 (68), pp. 93-98
- Furferi, R., Carfagni, M. (2010) *Prediction of the color and of the color solidity of a jigger-dyed cellulose-based fabric: A cascade neural network approach*, Textile Research Journal, Vol. 80, No. 16, pp. 1682-1696
- Li, H.-T., Shi, A.-S., Zhang, B.-S. (2007) *A dyeing color matching method combining RBF neural networks with genetic algorithms*, Proceedings - SNP'D 2007: Eighth ACIS International Conference on Software Engineering, Artificial Intelligence, Networking, and Parallel/Distributed Computing, Vol. 2, pp. 701-706
- Vadood, M., Semnani, D., Morshed, M. (2011) *Optimization of acrylic dry spinning production line by using artificial neural network and genetic algorithm*, Journal of Applied Polymer Science, Vol. 120, No. 2, pp. 735-744
- Nasiri, M., Shanbeh, M., Tavanai, H. (2005) *Comparison of statistical regression, fuzzy regression and artificial neural network modeling methodologies in polyester dyeing*, Proceedings - International Conference on Computational Intelligence for Modelling, Control and Automation, Vol.1, pp. 505-510
- Xu, B., Lin, S. (2002) *Automatic color identification in printed fabrics by a neural-fuzzy system*, AATCC Review, Vol. 2, No. 9, pp. 42-45
- Thevenet, L., Dupont, D., Jolly-Desoet, A.M. (2003) *Modeling color change after spinning process using feedforward neural networks*, Color Research and Application, Vol. 28, No. 1, pp. 50-58

12. Trussell, H.J. (1998) *Applications of digital signal processing, fuzzy logic, and neural nets to computational color*, Textile Chemist and Colorist, Vol. 30, No. 2, pp. 28-32
13. Lin, J.J., Sun, P.T., Chen, J.J.-R., Wang, L.J., Kuo, H.C., Kuo, W.G. (2010) *Applying gray model to predicting trend of textile fashion colors*, Journal of the Textile Institute Vol. 101, No. 4, pp. 360-368
14. Westland, S., Bishop, J.M., Bushell, M.J., Ushert, A.L. (1991, July/August). *An intelligent approach to colour recipe prediction*, JSDC, Vol. 107
15. Wu, P., Fang, S.-C., Nuttle, H.L.W., King, R.E., Wilson, J.R. (1994) *Decision surface modeling of textile spinning operations using neural network technology*. Proceedings of the 1994 IEEE Annual Textile, Fiber and Film Industry Technical Conference, p. 0-24
16. Yin, Y., Zhang, K., Lu, W. (2009) *Textile flaw classification by wavelet reconstruction and BP neural network*, 6th International Symposium on Neural Networks, Vol. 5552 LNCS, No: Part 2, pp. 694-701
17. Yean, Y., Wen, B.L., Ke, Z., Liang, J. (2009) *Textile flaw detection and classification by wavelet reconstruction and BP neural network*, Proceedings of the 2009 WRI Global Congress on Intelligent Systems, Vol. 4, pp 167-171
18. Liu, L., Yan, L., Xie, Y., Xia, G. (2010) *Content measurement of textile mixture by near infrared spectroscopy based on BP neural network*, Proceedings - 2010 3rd International Congress on Image and Signal Processing, Vol. 7, pp. 3354-3358
19. Kumar, A., (2003) *Neural network based detection of local textile defects*, Pattern Recognition, Vol. 36, No: 7, pp. 1645-1659
20. Su, T.-L., Kung, F.-C., Kuo, Y.-L. (2008) *Application of back-propagation Neural Network Fuzzy Clustering in textile texture automatic recognition system*, Proceedings of the 2008 International Conference on Wavelet Analysis and Pattern Recognition, Vol. 1, pp. 46-49
21. Islam, M.A., Akhter, S., Mursalin, T.E., Ashraful, A.M. (2006) *A suitable neural network to detect Textile defects*, Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), Vol. 4233 LNCS - II, pp. 430-438
22. Wu, P., Yang, W.-H., Wei, N.-C., (2004) *An electromagnetism algorithm of neural network analysis - An application to textile retail operation*, Journal of the Chinese Institute of Industrial Engineers, Vol. 21, No. 1, pp. 59-67
23. Bhattacharjee, D., Kothari, V.K. (2007) *A neural network system for prediction of thermal resistance of textile fabrics*, Textile Research Journal, Vol. 77, No. 1, pp. 4-12
24. Yuen, C.W.M., Wong, W.K., Qian, S.Q., Fan, D.D., Chan, L.K., Fung, E.H.K. (2009) *Fabric stitching inspection using segmented window technique and BP neural network*, Textile Research Journal, Vol. 79, No. 1, pp. 24-35
25. Luo, X., Hou, W., Li, Y., Wang, Z., (2007) *A fuzzy neural network model for predicting clothing thermal comfort*, Computers and Mathematics with Applications, Vol. 53, No. 12, pp. 1840-1846
26. Hadizadeh, M., Jeddi, A.A.A., Tehran, M.A. (2009) *The prediction of initial load-extension behavior of woven fabrics using artificial neural network*, Textile Research Journal, Vol. 79, No. 17, pp. 1599-1609
27. Yu, R.-F., Chen, H.-W., Cheng, W.-P., Hsieh, P.-H. (2009) *Dosage control of the fenton process for color removal of textile wastewater applying ORP monitoring and artificial neural networks*, Journal of Environmental Engineering, Vol. 135, No. 5, pp. 325-332
28. Chen, T., Zhang, C., Li, L., Chen, X. (2008) *Simulating the drawing of spunbonding nonwoven process using an artificial neural network technique*, Journal of the Textile Institute, Vol. 99, No. 5, pp. 479-488
29. Chen, T., Zhang, C., Chen, X., Li, L. (2009) *An input variable selection method for the artificial neural network of shear stiffness of worsted fabrics*, Statistical Analysis and Data Mining, Vol. 1, No. 5, pp. 287-295
30. Bo, Z. (2010) *The prediction of warp breakage rate of weaving by considering sized yarn quality using artificial neural network theory*, 2010 International Conference on Computer Design and Applications, , Vol. 2, pp. V2526-V2529
31. Nateri, A. S., Oroumei, A., Dadvar, S., Fallah-Shojaie, A., Khayati, Gh., Emamgholipour, O. (2010) *Using fuzzy expert system to simulating the antibacterial activity of nanosilver coated cotton fabrics*, Journal of Computational and Theoretical Nanoscience, Vol. 7, No. 8, pp. 1554-1558
32. Au, K.F., Wong, W.K., Zeng, X.H. (2006) *Decision model for country site selection of overseas clothing plants*, International Journal of Advanced Manufacturing Technology, Vol. 29, No. 3-4, pp. 408-417
33. Chen, X., Huang, X.B. (2004) *Evaluating fabric pilling with light-projected image analysis*, Textile Research Journal, Vol 74, No. 11, pp. 977-981
34. Karras, D.A., Karkanis, S.A. (1998) *Supervised and unsupervised neural network methods applied to textile quality control based on improved wavelet feature extraction techniques*, International Journal of Computer Mathematics, Vol. 67, No. 1-2, pp. 169-181
35. Lui, S.-G., Qu, P.-G. (2008) *Inspection of fabric defects based on wavelet analysis and BP neural network*, Proceedings of the 2008 International Conference on Wavelet Analysis and Pattern Recognition, Vol. 1, pp. 232-236
36. Stojanovic, R., Mitropoulos, P., Koulamas, C., Karayiannis, Y., Koubias, S., Papadopoulos, G. (2001) *Real-time vision-based system for textile fabric inspection*, Real-Time Imaging, Vol. 7, No. 6, pp. 507-518
37. Tolba, A.S., Khan, H.A., Mutawa, A.M., Alsaleem, S.M. (2010) *Decision fusion for visual inspection of textiles*, Textile Research Journal, Vol. 80, No. 19, pp. 2094-2106
38. Zeng, Y.C., Wang, K.F., Yu, C.W. (2010) *Predicting the tensile properties of air-jet spun yarns*, Textile Research Journal, Vol. 74, No. 8, pp. 689-694
39. Ramesh, M.C., Rajamanickam, R., Jayaraman, S. (1995) *Prediction of yarn tensile properties by using artificial neural networks*, Journal of the Textile Institute, Vol. 86, No. 3, pp. 459-469
40. Chattopadhyay, R., Guha, A., Jayadeva (2004) *Performance of neural networks for predicting yarn properties using principal component analysis*, Journal of Applied Polymer Science, Vol. 91, No. 3, pp. 1746-1751
41. Shi, X.-J., Yu, W.-D. (2008) *Fuzzy classification of animal fibers using neuro-fuzzy classifier*, Proceedings - The 1st International Conference on Intelligent Networks and Intelligent Systems, pp. 119-122
42. Shi, X.-J., Yu, W.-D. (2008) *Identification for animal fibers with artificial neural network*, Proceedings of the 2008 International Conference on Wavelet Analysis and Pattern Recognition, Vol. 1, pp. 227-231
43. She, F.H., Chow, S., Wang, B., Kong, L.X. (2001) *Identification and classification of animal fibres using artificial neural networks*, Seni Kikai Gakkai Shi/Journal of the Textile Machinery Society of Japan, Vol. 54, No. 9, pp. 60-63
44. Chen, T., Li, L., Koehl, L., Vroman, P., Zeng, X. (2007) *A soft computing approach to model the structure-property relations of nonwoven fabrics*, Journal of Applied Polymer Science, Vol. 103, No. 1, pp. 442-450

45. Kim, S., Vachtsevanos, G.J. (2000) *Intelligent approach to integration and control of textile processes*, Information sciences, Vol. 123, No. 3, pp. 181-199
46. Kim, S., Lee, M.H., Woo, K.-B. (1999) *Intelligent approach to integration of textile processes*, IEEE International Symposium on Industrial Electronics, Vol. 3, pp. 1454-1457
47. Kim, S., Lee, M.H. (1999) *Intelligent approach to integrated optimization and control of textile processes*, IEEE International Conference on Intelligent Robots and Systems, Vol. 3, pp. 1908-1913
48. Mori, T., Komiyama, J. (2002) *Evaluating wrinkled fabrics with image analysis and neural networks*, Textile Research Journal, Vol. 72, No. 5, pp. 417-422
49. Vroman, P., Koehl, L., Zeng, X., Chen, T. (2008) *Designing structural parameters of nonwovens using fuzzy logic and neural networks*, International Journal of Computational Intelligence Systems, Vol. 1, No. 4, pp. 329-339
50. Au, K.-F., Choi, T.-M., Yu, Y. (2008) *Fashion retail forecasting by evolutionary neural Networks*, International Journal of Production Economics, Vol. 114, No. 2, p. 615-630
51. Lin, J.-J. (2007) *Prediction of yarn shrinkage using neural nets*, Textile Research Journal, Vol. 77, No. 5, p. 336-342
52. Pynckels, F., Kiekens, P., Sette, S., Van Langenhove, L., Impe, K. (1995) Use of neural nets for determining the spinnability of fibres, Journal of the Textile Institute, Vol. 86, No. 3, pp. 425-437
53. Chattopadyay, R., Guha, A., *Artifical Neural Networks: Applications to Textiles*, The Textile Institute, Textile Progress, Vol. 35, No:1, p.5, p40
54. Bezerra, C.M., Hawkyard, C.J. (2000). *Match prediction for fluorescent dyes by neural networks*. J. Society of Dyers and Colourist, 116, pp. 163-169
55. Mizutani, E., Takagi, H., Auslander, D.M., Jang, J-S., R. (2000, November). *Evolving Color Recipes*. IEE Transactions on Systems, Man, And Cybernetics, Part- C: Applications and Reviews, Vol.30, No: 4, pp. 537-550
56. Limin, F. (1994). ISBN: 0-07-113319-4. *Neural networks in computer intelligence*. McGraw-Hill International Editions, Computer Science Series. The MIT Press & McGraw Hill, Inc., Singapore, p. 460.
57. Bishop, J.M., Bushnell, M.J., Westland, S. (1991). *Application of neural network to computer recipe prediction*. Color Research and Application. 16(1), pp.3-8
58. Vangheluwe, L. (1994), *Comments on "Using Neural Networks to Predict Dye Concentrations in Multiple-Dye Mixtures"* TRJ, 64(3), pp. 182-183
59. Jasper, W.J. (1994). *Reply to "Using Neural Networks to Predict Dye Concentrations in Multiple-Dye Mixtures"*. TRJ, 64(3), pp. 184
60. Marjoniemi, M.,& Maentysalo, E. (1997). *Neuro-fuzzy modelling of spectroscopic data. Part B- Dye concentration prediction*. J. Society of Dyers and Colourist, 113, pp. 13-17
61. Westland, S. (2002). *Kubelka- Munk or Neural Networks for Computer Colorant Formulation*. 9th Congress of the International Color Association, Proceedings of SPI Vol. 4421
62. Mizutani, E., Jang, J-S., R., Nishio, K., Takagi, H., Auslander, D.M. (1995, November). *Coactive Neuro-Fuzzy Modeling for Color Recipe Prediction*. Proc. IEEE Int. Conf. Neural Networks, pp. 2252-2257