



## Support System of Acceptance-Rejection Decision for Incoming Quality Control Process

Duygu YILMAZ EROĞLU\*

Bursa Uludag University, Faculty of Engineering, Department of Industrial Engineering, Görükle Campus 16059, Nilüfer/BURSA

### Graphical/Tabular Abstract

In this paper, three different methodologies are proposed for classification problem in the real production environment. Hybrid genetic algorithm is adapted to the current problem and the results compared with hybrid radial basis function. After validating hybrid genetic algorithm, the best chromosome's genes' values are used as coefficients to predict the classes for the first time in this study.

### Article Info:

Received: 05/04/2019

Revision: 10/07/2019

Accepted: 15/07/2019

### Highlights


- Genetic Algorithms
- Neural Networks
- Classification

### Keywords

Hybrid genetic algorithm  
Hybrid RBF  
Classification

```

If
b * Value of Strength + h * Value of ΔE ≤ Threshold
Then 'Accept'
Else 'Reject' the sample
  
```



<sup>1</sup>: This is the best chromosome schema after running the hybrid genetic algorithm with considered (example) dataset. If another dataset would be used, the coefficients will be changed. If the 'Select' value of the gene is smaller than 'Do not select' value, then select the feature. The characters that indicated in bold, shows the smaller value for gene couples.

Figure A. Chromosome schema

**Purpose:** The aim of this paper is to build a predictive decision support model which will support the decision making of yarn acceptance at the incoming quality control stage of the actual production environment.

**Theory and Methods:** Hybrid genetic algorithm, in which the k-NN classifier with variable k policy and local search is embedded, is applied as the first solution method. Radial basis function (RBF) that is hybridized with recursive least squares estimation (RLS) method is utilized as a second solution method. Finally, since both important attributes and their coefficients can be taken directly from the best chromosome of the hybrid genetic algorithm, the third technique is proposed as using these coefficients by multiplying with attribute values and then comparing with the threshold value to accept/reject the sample.

**Results:** Average accuracy rates of hybrid genetic algorithm and hybrid RBF are 90.14% and 90.25% respectively. These two methods then compared with Naive Bayes and IBk and applied methods, outperformed both of them. The accuracy rate of the proposed third method is calculated as 88.95%. The result is compared with multiple linear regression, and it is observed that the proposed method outperformed with a significant margin.

**Conclusion:** In this study, the predictive decision system models are suggested to accept or reject decision for yarn acceptance process in a textile factory in Bursa/Turkey. More than 1200 samples are used to run hybrid genetic algorithm, hybrid RBF, and regression-based method, which utilize the best chromosome's genes' random numbers of hybrid genetic algorithm. Although this technique's performance is less than the hybrid genetic algorithm and hybrid RBF, it is clear that it is a convenient methodology that can be preferred in terms of ease of use.



## Giriş Kalite Kontrol Sürecinde Kabul-Ret Kararı Destek Sistemi

\*Duygu YILMAZ EROĞLU

Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Görükle Kampüsü, 16059 Nilüfer/BURSA

### Öz

Bu çalışmada, iplik kalite kabul sürecindeki dört adet girdi faktörünün yanında, çalışanların karar alma konusunda uzman görüşlerinin de dikkate alındığı bir yapı için öngörü destek sistemleri tasarlanmıştır. İlk yöntem, daha önce sınıflandırma çalışması için tasarlanıp doğrulanan melez genetik algoritma olup mevcut çalışmaya adapte edilmiştir. Diğer metod ise, sinirsel ağlar temelli melez radyal tabanlı fonksiyondur ve probleme uygun hale getirilerek kodlanmıştır. Gerçek üretim verilerinin kabul-ret kararı için sınıflandırılması sürecinde, geliştirilen iki teknik ile %90'ın üzerinde doğruluk oranı elde edilmiş, literatürde iyi bilinen diğer bazı yöntemler de performans karşılaştırmasında kullanılmıştır. Melez genetik algoritmanın performansı doğrulandıktan sonra, elde edilen en iyi kromozom, sınıflandırma tahmin modeli olarak kullanılmıştır. Önerilen metodolojiye göre, seçilen öznelik değerleri, belirlenen katsayılar ile çarpılmış ve bir eşik değeri ile karşılaştırılarak makul bir doğruluk oranı ile kabul-ret kararı verilebilmiştir. Makalenin literatüre katkısı ise iki şekilde değerlendirilebilir. İlki, önerilen melez genetik algoritmanın sınıflandırma performansının melez sinirsel ağlar yöntemi ile karşılaştırılması, ikincisi, önerilen melez genetik algoritma sonucunda elde edilen en iyi kromozomun iplik kalite kabul süreci için destek sistem olarak kullanabilmesidir.

### Makale Bilgisi

Başvuru: 05/04/2019  
Düzeltilme: 10/07/2019  
Kabul: 15/07/2019

### Anahtar Kelimeler

Melez genetik algoritma  
Melez radyal tabanlı  
fonksiyon  
Sınıflandırma

### Keywords

Hybrid genetic  
algorithm  
Hybrid RBF  
Classification

## Support System of Acceptance-Rejection Decision for Incoming Quality Control Process

### Abstract

In this study, predictive support systems have been designed for a structure in which takes into account the expert opinions of employees for decision making in addition to four input factors in a yarn quality acceptance process. The first technique is a hybrid genetic algorithm which was previously designed and validated for the classification study and adapted to the current problem. The other method is a hybrid radial based function (RBF) based on neural networks which is adapted to the problem and coded. During the process of classifying the actual production data for the accept-reject decision, accuracy rate of more than 90% has been achieved with two techniques developed and also some other methods which are well-known in literature were used for performance comparison. After the verification of the hybrid genetic algorithm performance, the best chromosome that was obtained, used as the model for classification estimation. According to the proposed methodology, the selected attribute values were multiplied by the determined coefficients and compared with a threshold value, and an acceptance-rejection decision could be made with a reasonable accuracy rate. The contribution of the article to the literature can be evaluated in two ways. The first one is comparing the classification performance of the proposed hybrid genetic algorithm with the hybrid neural networks method, and the second one is utilizing the best chromosome of the proposed genetic algorithm as a support system for yarn quality acceptance process.

## 1. GİRİŞ (INTRODUCTION)

Sanayide dijitalleşme, literatürde OODA ( observe–orient–decide–act) döngüsü olarak bilinen, temellerini insan beyninin karar verme mekanizmasından alan, Amerika Birleşik Devletleri Hava Kuvvetleri'nde hava muharebesi için Albay John Boyd tarafından geliştirilen [1] adımları içermektedir. Zamana dayalı rekabet, gerçek zamanlı işletme, sıfır gecikme süresi, çevik işletme, uyarlanabilir işletme gibi birçok yönetim stratejisinin temelinde, firmaların değişime olan cevapları esastır. Günümüzde, iş liderleri üç yeni soruyu sormakta; şu anda neler oluyor? Olası muhtemel olaylar nelerdir? Hangi olaylar geleceği

etkileyebilir? [2] Bu soruları üretim ortamında cevaplandırabilmek için, gözlem (observe) aşamasından verilerin anlık toplanması, adaptasyon (orient) aşamalarında analizlerin yapılması, geliştirilen algoritmaların kullanılarak karar verilmesi ve uygula (act) aşamasında geliştirilen karar destek sisteminin adapte edilmesi gerekir. Bu döngünün canlı tutulabilmesindeki en önemli koşul ise geri besleme (feedback) olup tüm aşamalarda dönütlerin gözlem aşamasına girdi olarak kullanılabilmesini gerektirir. Veri madenciliği yöntemleri de bu döngünün adaptasyon ve karar aşamalarında sıklıkla kullanılmaktadır. Bu perspektif ile bakıldığında –çalışmamızda da odaklanılacak olan- kararı en fazla etkileyen özniteliklerin seçilmesi, ağırlıklandırılması, seçilen ve ağırlıklandırılan öznitelikler kullanılarak yeni verinin sınıfının tahmin edilmesi için geliştirilen algoritmalar, insan beynini taklit etmeye çalışan bir karar destek sisteminin parçalarıdır.

Bu makalede, bir doküma firmasının iplik kalite kabulü için gereken girdi parametrelerinin (faktör ya da öznitelik olarak da belirtilebilir) hızlı ve doğru şekilde değerlendirilerek kabul ya da ret kararının verilmesini destekleyen bir karar destek sistemi üzerinde çalışılmıştır. Gerçek sistemde, her bir kabul faktörü için alt ve üst limitler belirlenmiştir. Fakat limitler içerisinde olsa dahi tüm ipliklerin uzman çalışanın onayını alması gerekmektedir. Sonuç olarak, sadece uzman çalışan onayını da alan iplikler üretim aşamasına gönderilmektedir. Önerilen algoritmalar, kabul kararında insan faktörünün de yer aldığı uzman sistem modelleridir. Bu anlamda yapılan çalışma, kabul kararında faktör etkisinin araştırılması niteliğindedir. Çalışmada, daha önce sınıflandırma ve öznitelik seçimi problemleri için kullanılan melez genetik algoritma, sinirsel ağlar yöntemleri ile karşılaştırılmıştır. Önerilen melez genetik algoritmanın sınıflandırma başarısı %90.14 olup, RLS (recursive least squares estimation-özyinelemeli en küçük kareler) ile melezleştirilmiş RBF (radial basis function-radyal tabanlı fonksiyon) problem için kodlanmış ve %90.25 sınıflandırma başarısı elde edilmiştir. Hedef ise, regresyon yönteminde olduğu gibi katsayıların parametre değerleri ile çarpılarak sonuç değer tahmininde kullanılması olduğundan, melez genetik algoritmanın son aşamasındaki en iyi kromozomun ağırlıkları kullanılacaktır. Elde edilen bu ağırlıklar ile karşılık gelen parametre değerleri çarpılmış, hesaplanan değer belirlenen eşik değeri ile karşılaştırılmış ve kabul/ret kararı verilmiştir. Test aşamasında, sonuçların %88.95 doğru tahmin edildiği gözlemlenmiştir. Esinlenen yöntem olan regresyonda ise doğruluk oranı %64.53 değerine kadar ulaşabilmiştir. Elde edilen tüm bu sonuçlara göre, önerilen melez genetik algoritma, iplik kalite kabulü aşamasında bir öngörü olarak dikkate alınarak kabul sürecin hızlandırılması sağlanacaktır.

Makalenin 2. Bölümü, ilgilenilen konular ile ilgili literatürde daha önce yapılan çalışmaları, 3. bölüm melez genetik algoritma temel adımlarını, 4. bölüm, probleme özgü sinirsel ağ algoritmalarını detaylandırmaktadır. 5. bölümde hesaplama sonuçları karşılaştırılarak algoritma performansları ortaya konmuş, son olarak 6. bölüm ile makale tamamlanmıştır.

## 2.LİTERATÜR TARAMA (LITERATURE REVIEW)

Yapılan sınıflandırma çalışmaları iki koldan yürütülmüştür. İlki, ağırlıklandırılmış öznitelik seçimi ile sınıflandırma yapan melez genetik algoritma, diğeri ise sinirsel ağlar çalışma kapsamında yer alan melez RBF'dir. İki algoritma performansının karşılaştırılmasının ardından, melez genetik algoritma ile elde edilen en iyi kromozom katsayılarının sınıf tahmininde bulunması için geliştirilen, çoklu regresyondan esinlenen metot da bir tahmin öngörü yöntemi olarak önerilmiştir. Literatür taraması da bu kapsamda ilerletilerek, öznitelik seçim algoritmaları, sezgisel yöntemlerle sınıflandırma çalışmaları, sinirsel ağlar ile sınıflandırma çalışmaları, eş zamanlı sınıflandırma ve ağırlıklandırma algoritmaları ve regresyon tabanlı yöntemler irdelenmiştir.

Öznitelik seçimi, sonuç değerine en fazla katkıda bulunan özellikleri belirleme işlemidir ve doğru şekilde yapılabilirse, özellikle büyük veriler içeren sistemlerde modelin yüksek doğrulukta tahminler yapabilmesini kolaylaştırır. Konu ile ilgili literatür tarama çalışmaları farklı tarihlerde yapılmış ve çok değerli bilgileri hassasiyetle derleyebilmiştir [3, 4, 5]. Bu çalışmalarda da gözlemlenebileceği gibi, meta sezgisel yöntemler öznitelik seçimi problemlerinde sıklıkla kullanılmıştır. Örneğin Seera ve Lim [6], bulanık min-max sinirsel ağlar, sınıflandırma ve regresyon ağacı ve rasgele orman algoritmalarını içeren melez algoritma önermişler, algoritmayı UCI [7] veri bankası'ndaki tıbbi veri setlerine uygulamış ve sonuçları literatürdeki sonuçlar ile karşılaştırılarak doğrulamışlardır. Marinakis ve ark. [8] tarafından yapılan diğeri bir çalışma, önerilen melez

parçacık yığın optimizasyonu-değişken komşuluk arama algoritması olup öznelik altkümesi belirleme amacı ile kullanılmıştır. Öznelik seçimi konusunda genetik algoritma kullanan algoritmaların önemli bir kısmının kromozom yapılarında, seçilen parametrelerin, 1 seçilmeyen parametrelerin 0 ile gösterildiği (ikili gösterimin kullanıldığı) gözlemlenmiş ve bahsi geçen çalışmaların bazıları bu paragrafta derlenmiştir. Chatterfee ve Bhattacharjee [9] tarafından yapılan bir makalede, bir demir madeninde, ürünlerin kalite parametrelerini belirleme konusunda, öznelik seçimi için genetik algoritma kullanılmıştır. Çalışmada, kromozomun uygunluk fonksiyon değerini değerlendirmek için bir sinirsel ağ yapısı geliştirilmiştir. Diğer bir çalışmada ise genetik algoritma, hem öznelik hem de örnek seçimi için kullanılmış, böylece büyük veri seti küçültülebilmektedir [10]. El yazısı tanıma üzerine odaklanan, Das ve ark. [11] tarafından yapılan bir çalışmada ise genetik algoritma yanında diğer bazı meta sezgiseller de kullanılmış en yüksek doğru tanıma oranı alanında genetik algoritmanın diğer yöntemlerden daha iyi çalıştığı sonucuna ulaşılmıştır.

Sınıflandırma, sınıf sayısının ve eldeki verilerin hangi sınıfa ait olduğunun bilindiği durumlarda, yeni verinin hangi sınıfa ait olabileceğinin tahmin edilmesidir. Karar ağaçları, en yakın komşuluk yaklaşımı, kural tabanlı yaklaşımlar, bayes sınıflandırıcı yaklaşımı, sinirsel ağlar gibi çok sayıda temel metot ve bu metotların geliştirilmiş versiyonları veri madenciliği temel yöntemlerini oluşturmaktadır [12]. Araştırmacılar, sınıflandırma problemlerinin çözümünde meta sezgisel yöntemlerden de sıklıkla yararlanmışlardır [13]. Farklı sınıflandırıcıların entegre edilerek genetik algoritmanın melezleştirildiği yöntemler, ihtiyaç duyulan alanlardaki problemler için etkili sonuçlar sergilemiştir. Zhao ve ark. [14] sınıflandırıcı olarak SVM (support vector machine-destek vektör makinesi) kullanan genetik algoritma önermişlerdir. Algoritma, eşzamanlı olarak SVM parametrelerini ve öznelik altkümesini eniyileyebilmek üzere çalışmış ve etkili sonuçlar elde edilmiştir. SVM'nin sınıflandırıcı, genetik algoritmanın arama algoritması olarak kullanıldığı diğer bir makalede, hiperspektral görüntü sınıflaması yapılmıştır [15]. Eritemato-skuamöz hastalık tanısı konusunda, Ozcift ve Gulden [16] tarafından yapılan çalışmada, bayes ağları sınıflandırıcısı ile melez özellik kazandırılan genetik algoritma, diğer yöntemlere kıyasla hastalığı teşhis etmede etkili bir araç olarak öne çıkmıştır.


Optimizasyon, parametrik ve kontrol optimizasyonu olarak gruplandırılırsa, sinirsel ağlar, parametrik optimizasyon altındaki sürekli yapının bir kolu olarak değerlendirilebilir. Literatürde sıklıkla başvuru alan sinirsel ağlar kapsamında tanımlanmış çok sayıda algoritma mevcuttur. Doğrusal ve doğrusal olmayan fonksiyonların kullanıldığı sinirsel ağların birçok avantajından bazıları, neden sonuç ilişkisi yaratmaya yardımcı olmaları, verilerin değişkenliğine adapte olabilmeleri ve farklı yapıların eklenip çıkarılmasına uygun olmaları olarak sıralanabilir [17]. RBF ise, daha genel tahminci olması ve öğrenme hızının, lokal olarak ayarlanmış nöronlar sayesinde yüksek olması nedeni ile diğer sinirsel ağlardan farklılaşmaktadır [18]. RBF'in literatürde sıklıkla kullanıldığı alanlar örüntü tanıma ve sınıflandırma uygulamalarıdır [19, 20]. Bu makale kapsamında, önerilen melez genetik algoritma, melez RBF sinirsel ağlar yöntemi ile doğrulandığı için, RBF ile sınıflandırma yapan yöntemlerden bazıları da literatür tarama kapsamında irdelenmiştir. Fu ve Wang [21], önerdikleri ayrılabilirlik-korelasyon ölçüsü ile öznelik sayısını azaltarak RBF ağı karmaşıklık derecesini düşürmüş ve yüksek sınıflandırma performansı elde etmişlerdir. Çalışmada, sonuçların geçerlilikleri, UCI veri bankası [7]'daki bazı veri setleri kullanılarak doğrulanmıştır. Janik ve Lobos tarafından yayınlanan makalede, voltaj bozulmalarının otomatik sınıflandırması için SVM önerilmiş, sonuçları doğrulamak için ise RBF ile ilgili de çalışmalar yapılmıştır [22]. Literatürde, radyal tabanlı sinir ağları eksik verilerin tahmini için de kullanılmıştır [23]. 2018 yılında, tekstil sektöründe veri madenciliği ve makine öğrenmesi ile ilgili yapılan literatür taraması'nda sektörün problemlerine odaklanarak, farklı sınıflandırma ve kümeleme algoritmaları ile çözüme ulaşılmış yetmiş adedin üzerinde makale incelenmiştir [24]. Bahsi geçen çalışmaya göre, yün iplik bobinlerinin kuruma sürelerinin tahmini için RBF kullanan Akyol ve ark.[25], algoritmalarının performansını beş farklı metot ile karşılaştırarak ortaya koymuşlardır. Yıldız ve ark. [26] tarafından yapılan diğer bir çalışmada da, poplin ve gabardin dokuma kumaş kıyafetlerinin dikiş mukavemeti ve kopma uzaması modellenmesi için MLP (multilayer perceptron-çok katmanlı algılayıcı) ve RBF kullanılmış, benzer sonuçlar elde edilmiştir. Behera ve Karthikeyan [27] tarafından yayınlanan bir makale gölgelik kumaşlarının konstrüksiyon ve performans parametrelerinin tahmini için RBF kullanmıştır. Nurwaha ve Wang ise eğrilmiş iplik kalite tahmini için, aralarında RBF yönteminin de olduğu akıllı kontrol sistemlerini kullanmış ve yöntemleri istatistiksel olarak karşılaştırmışlardır [28]. Kotb [29] tarafından yapılan bir çalışmada da Mısır'da üretim yapan bir firmada, pamuk ve polyester iplik kalitesine etki eden faktörler lineer regresyon yöntemi ile belirlenmiştir. Abakar ve Yu [30], yaptıkları çalışmada iplik kalitesini etkileyen faktörlerin belirlenmesinde yapay sinirsel ağlar ve SVM yöntemleri karşılaştırmış, sonuç olarak, RBF ve PUK (Pearson VII Universal Kernel) tabanlı SVM

ile elde edilen sonuçların yapay sinirsel ağlardan daha iyi sonuçlar verdiğini gözlemlemişlerdir. İplik kalitesini etkileyen faktörlerden lif sayısını etkileyen parametreler ise Amin ve ark. [31] tarafından regresyon yöntemi ve istatistiksel teknikler ile belirlenmiştir. Raggi ve Barbiroli tarafından yapılan çalışmada da renk fark değeri olan Delta E üzerinde temel istatistiki çalışmalar yapılmıştır [32]. Literatürde ilaveten, dayanıklılık [33] ve burulmanın [34] iplik kalitesine etkileri ile ilgili çalışmalar da bulunmaktadır.

Bazı çalışmalarda ise, özneliğin sonucu etkileme derecesi öne çıkar. Bu tip problemlerin çözümünde ise öznelik ağırlıklandırma algoritmaları geliştirilmiştir. Esasında bu tip algoritmalarda, öznelik 0 değeri aldığında algoritma öznelik seçim algoritması olarak da ilerlemektedir. Literatür, öznelik ağırlıklandırma konusunda, öznelik seçimine göre daha az sayıda çalışma içermektedir. Eşzamanlı olarak öznelik seçimi ve öznelik ağırlıklandırma yapan algoritmalar genellikle sınıflandırıcı algoritmaları da içerisinde barındırmaktadır. Örneğin Tahir ve ark. [35] tarafından geliştirilen melez tabu arama algoritması, içerisine gömülü k-NN sınıflandırıcısı ile eşzamanlı öznelik seçim ve ağırlıklandırma yapmaktadır. Algoritmada k değişkendir. Konu ile ilgili, bu makaledeki genetik algoritmanın da temelini oluşturan çalışmada [36], eşzamanlı öznelik seçimi ve ağırlıklandırması birlikte yapılmış, değişken k'nın yer aldığı k-NN sınıflandırıcısı melez genetik algoritma içerisine gömülmüştür. Algoritmanın sınıflandırma performansı, UCI [7] veri tabanındaki veri setleri kullanılarak doğrulanmış ve sonrasında firmaların inovasyon seviyelerine etki eden faktörlerin en önemlileri belirlenmiştir. Bu makalede, temelde benzer algoritma kullanılacak, probleme özel adaptasyonlar yapılacak, sinirsel ağlar ile performans karşılaştırması yapılacak ve elde edilen öznelik ağırlıkları doğrudan kabul ret kararının verilmesinde bir formülasyonun içinde kullanılacaktır. Sonucun tahmininde faktör ağırlıklarını kullanmak regresyon tabanlı yöntemleri [37, 38] daha uygulanabilir kılmaktadır. Sektörde hızlı karar vermeyi kolaylaştıracak yaklaşımlara olan ihtiyaç nedeniyle, son aşamada, önerilen melez genetik algoritma ile elde edilen ağırlıklar, iplik üreticisinden gelen lotların kabul ya da ret kararında bir öngörü bilgi olarak kullanılacaktır.

### 3. MELEZ GENETİK ALGORİTMA İLE SINIFLANDIRMA (CLASSIFICATION VIA HYBRID GENETIC ALGORITHM)

Sınıflandırıcı olarak k-NN algoritmasının kullanıldığı, genleri rassal sayılardan oluşan ve bu rassal sayıların aynı zamanda özneliklerin ağırlıklarını gösterdiği, lokal arama ile melezleştirilmiş genetik algoritmanın [36] etkinliği, daha önceki çalışmalarda farklı veri kümeleri ve algoritmalar ile karşılaştırılarak doğrulanmış olup, bu çalışmada algoritma, iplik kalite kabul problemine özel adaptasyonlarla güçlendirilmiştir. Örnek kromozomun Şekil 1'deki gibi gösterildiği yapıda, her bir gen içerisindeki rassal sayılar, 0 ile 1 arasında düzgün dağılıma göre türetilmiştir. Her gen çifti bir özneliğe atanmış olup, eğer gen çiftinin ilk değeri en küçük değere sahip ise incelenen öznelik, öznelik kümesine dahil edilmez (seçilmez), aksi durumda öznelik seçilir. Seçilen özneliklerin ağırlıkları da rassal sayılardır. Şekil 1'deki yapı üç öznelik içeren bir kromozomu temsil etmektedir. Öznelik 1 için türetilen iki rassal sayı olan 0.21 ve 0.32 karşılaştırıldığında ilk rassal sayı daha küçük olduğundan, 0.21 üzerinden ilerlenir ve bu gene karşılık gelen seçim kararı uygulanır (0 → Seçim negatif). Bu karara göre Öznelik 1, öznelikler kümesine dahil edilmemiştir. Benzer çalışma Öznelik 2 için yapıldığında, 0.63 ve 0.14 karşılaştırılır ve 0.14 daha küçük sayı olduğu için bu gene karşılık gelen seçim kararı olan 1'e göre Öznelik 2 seçilir. Öznelik 3 için de benzer karşılaştırmalar yapıldıktan sonra seçim kararı verilmiştir. Bu kromozomdaki rakamlara göre Öznelik 2 ve Öznelik 3 seçilmiş, ağırlıkları da sırasıyla 0.14 ve 0.76 olarak belirlenmiştir.



Şekil 1: Melez genetik algoritma kromozom yapısı

Önerilen algoritmanın ana adımları aşağıdaki gibidir.

- I. Veri önışlemeden geçirilir. Doğrusal ölçeklendirmenin uygulandıđı bu aşamada, her bir öznelik, (1) numaralı formülasyona göre 0 ile 1 arasında ölçeklendirilir. Bu formülasyonda  $v$  orijinal deđeri,  $v'$  ölçeklendirilmiş deđeri,  $max$  özneliđin en büyük deđerini,  $min$  özneliđin en küçük deđerini ifade etmektedir.

$$v' = \frac{v - min}{max - min} \quad (1)$$

- II. Önerilen yöntemin sınıflandırma doğruluk oranı 10-katlı çapraz doğrulama (10-fold cross validation) yöntemi ile hesaplanmıştır. Sınıflandırıcı doğrulaması için kullanılan yöntemde öncelikle, veri eşit büyüklükte 10 alt kümeye ayrılır. Sonrasında, sırasıyla her alt küme test için ve geri kalan eğitim için kullanılır. Sonuç olarak,  $n$  örnekleme sahip veri seti  $f=10$  kat (fold)'a bölünmüştür.  $f=1$ 'den  $10$ 'a kadar her  $f$  katı için aşağıdaki hesaplamalar yapılır.

- i. Veri setinin  $f$ 'inci  $n/10$  adet verisi test verisi olarak ayrılır.
- ii. Kalan  $n-(n/10)$  adet veriyi kullanarak eğitim yapılır. Bu aşamada, eğitim verisinin  $2/3$  adedi doğrudan eğitimde,  $1/3$  adedi doğrulama aşamasında kullanılır.
  - a. Melez genetik algoritma kullanılarak öznelikler ve ağırlıklarının tanımlı olduđu başlangıç popülasyon oluşturulur. Hem başlangıç popülasyonu, hem de sonraki nesillerdeki her bir kromozomun uygunluk fonksiyonu deđeri hesabı için, hem öznelik sayısını azaltmaya, hem de doğruluk oranını arttırmaya çalışan, Zhao ve ark. [14] tarafından önerilen algoritmadan esinlenilerek oluşturulan, (2) numaralı formülasyon kullanılır.

$$Uygunluk\ fonksiyonu = 1 - \left( 0.999 * \frac{Toplam\ Hata\ Sayısı}{Test\ örneklem\ Sayısı} + 0.001 * \left( 1 - \left( P + \frac{Seçilen\ öznelik\ sayısı}{Öznelik\ Sayısı} \right)^{-1} \right) \right) \quad (2)$$

- b. Her bir kromozom için k-NN sınıflandırıcısı kullanılır. Bu sınıflandırıcıda, eğitim kümesindeki bilinmeyen örnek (doğrulama verisi), en yakın  $k$  adet komşusunda en sık görülen sınıf etiketi ile sınıflandırılır. Melez genetik algoritmada,

- ✓  $k$  deđeri kromozoma bir gen olarak eklenmiş olup deđişkendir ve kromozomda 3-10 arasında deđer atanır. En iyi kromozom, en iyi  $k$  sayısını da belirlemiş olacaktır. Eğitim setinin  $1/3$ 'üne karşılık gelen her bir doğrulama verisi için aşağıdaki hesaplama yapılır;
  - Eğitim setinin  $2/3$ 'ne karşılık gelen eğitim setine Öklid uzaklıđı hesaplanır.
  - En küçük mesafenin hesaplandıđı  $k$  adet veri seçilir.
  - Bu verilerin sınıfları arasında en fazla tekrar eden sınıf, tahmin edilen sınıftır.
  - Eđer tahmin edilen sınıf deđeri, doğrulama verisindeki gerçek sonuçtan farklı ise hata sayısı deđeri 1 arttırılır.

- ✓ Uygunluk fonksiyonundaki Toplam Hata Sayısı, doğrulama veri kümesindeki her bir veri için elde edilen hata sayılarının toplamı ile bulunur.

- c. Lokal arama: Tüm kromozomların en iyi uygunluk fonksiyon deđerine ulaşabilmesi için lokal arama uygulanır. Buna göre, daha önce seçilmeyen bir özneliđin seçilme durumu ve seçilmiş olanın ağırlıđının deđişme durumları gözden geçirilir. İlgilenilen kromozomun, lokal arama ile en iyilenmesi sağlanır.
- d. Doğrululuk oranı deđerinin hesaplanması: İterasyonlar, belirlenen nesil sayısı kadar ilerletildikten sonra, elde edilen en iyi kromozoma ulaşılır. Bu kromozom kullanılarak, daha önce test için ayrılan test kümesi verileri ile doğruluk oranı hesaplanır.
- iii. İlaveten her bir kat için algoritma 10 kez çalıştırılmış, elde edilen doğruluk deđerlerinin ortalaması ilgili kat için doğruluk deđeri olarak kaydedilmiştir. Sonuç olarak elde edilen doğruluk oranı deđeri, algoritmanın 100 kez çalıştırılması ile elde edilmiştir

Önerilen algoritma, C# programlama dilinde kodlanmış olup algoritmanın deneysel tasarımına ve sonuçlarına dair yorumlar 5. Bölümde detaylandırılmıştır.

#### 4. MELEZ RBF İLE SINIFLANDIRMA (CLASSIFICATION VIA HYBRID RBF)

Bu bölümde detaylandırılan RLS Yaklaşımı ile melezleştirilmiş RBF algoritması, Matlab R2013a programlama ortamında kodlanmıştır. İplik kalite kabul örneği üzerinde yapılan analiz sonuçları ve karşılaştırmalar, sonraki bölümde detaylandırılmıştır.

RBF sinirsel ağının anlatımı için Şekil 2'deki yapı ve aşağıdaki açıklamalar dikkate alınabilir [17]. Bu yapı üç katmandan oluşur.

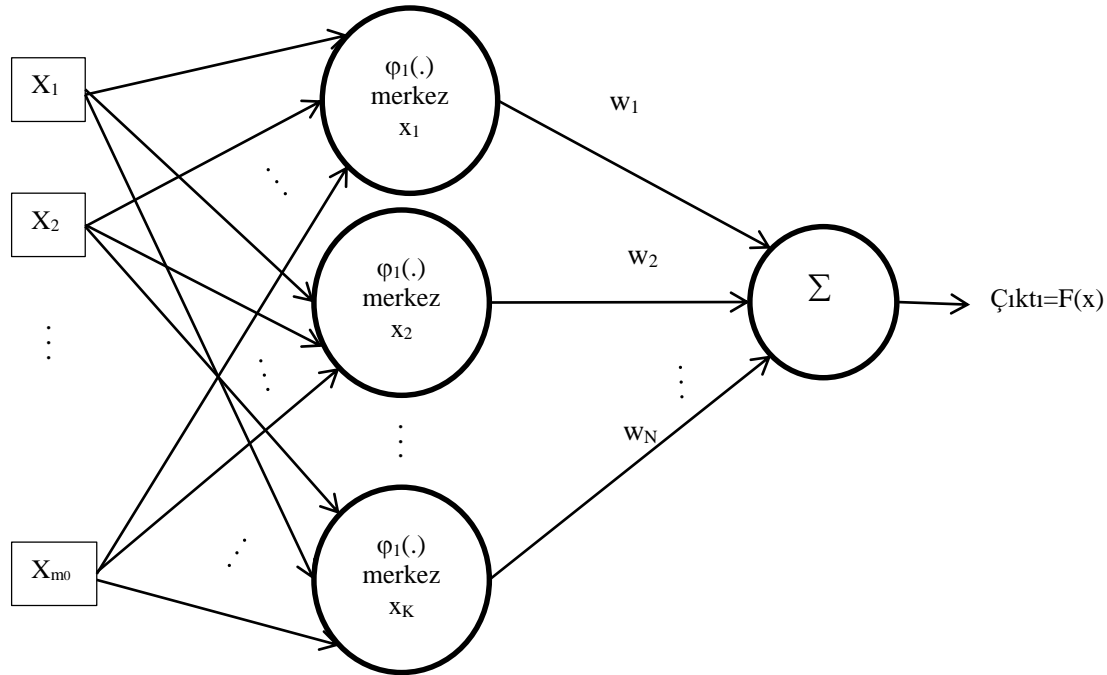
1. Girdi katmanı:  $m_0$  adet kaynak düğümü içerir. Burada  $m_0$  girdi vektörü olan  $x$ 'in boyutudur. Örneğimizde iplik kalite kabul kararını etkileyen özneliklerdir.
2. Gizli katman: Eğitim örnekleminde daha az sayıda  $K < N$  hesaplama birimi içerir. Her birim matematiksel olarak radyal tabanlı fonksiyon olarak tanımlanabilir. Radyal tabanlı fonksiyon olarak Gauss fonksiyonu kullanıldığında, gizli katmandaki her bir hesaplama birimi için (3) no'lu formülasyon yazılabilir. Bu formülasyonda  $\sigma_j, x_j$  merkezli Gauss fonksiyonunun genişliğidir.

$$\varphi_j(x) = \varphi(x - x_j) = \exp\left(-\frac{1}{2\sigma_j^2} \|x - x_j\|^2\right), \quad j = 1, 2, \dots, K \quad (3)$$

$j$ . girdi veri noktası olan  $x_j$ , radyal tabanlı fonksiyonun merkezini, ve  $x$  vektörü girdi katmanına gönderilen sinyali gösterir.

3. Çıktı katmanı: Şekil 2'deki çıktı katmanı, (4) no'lu formülasyonda gösterildiği gibi tek hesaplama birimi içermektedir.

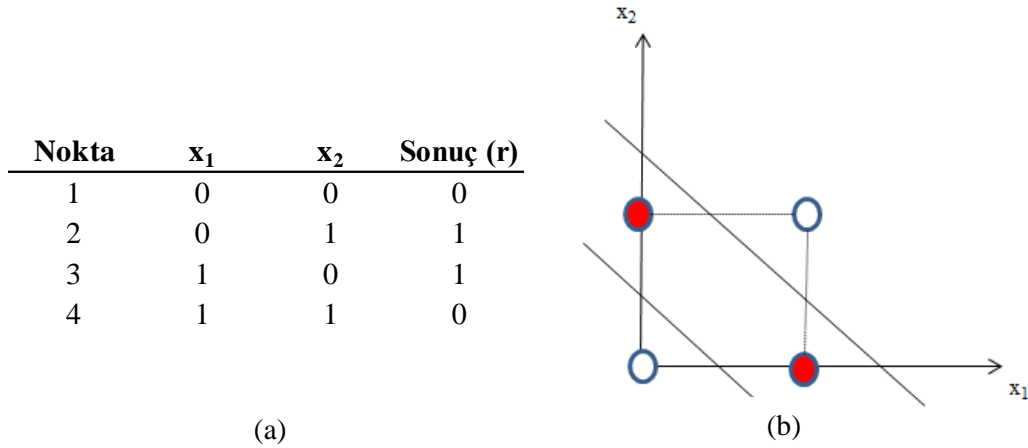
$$F(x) = \sum_{j=1}^K w_j \varphi_j(x, x_j) \quad j = 1, 2, \dots, K \quad (4)$$



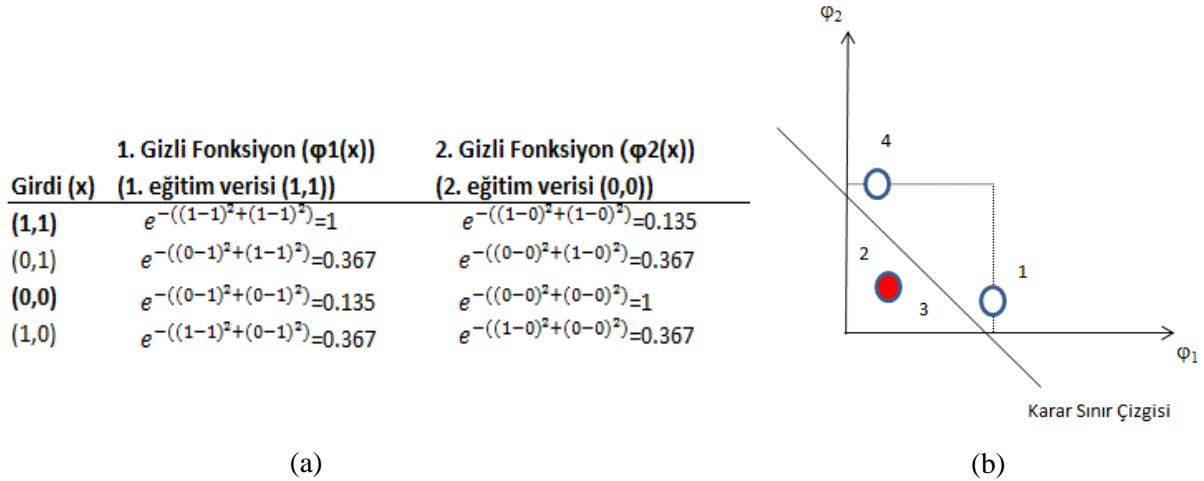
Şekil 2: RBF ağının yapısı

Yöntem, literatürde de sıklıkla kullanılan, lineer olarak ayrıştırılamayan XOR örneği ile daha iyi anlaşılabilir. Şekil 3 (a), her bir noktanın  $x$  değerlerini ve XOR fonksiyonu sonrasında elde edilen sonuç değerini göstermektedir. Şekil 3 (b),  $x_1$  ve  $x_2$  eksenlerinde noktaların yerini göstermektedir. Problemin çözümü için doğrusal olmayan gizli katman kullanımı işe yarayacaktır. RBF yönteminin uygulanış adımları ise Şekil 4 (a)'daki gibidir. Burada, gauss fonksiyonu sayesinde XOR, doğrusal olarak birbirinden ayrılabilen bir yapıya sahip olmuştur. Şekil 4(b)'deki grafik de bu durumu doğrulamaktadır. Şekil 5 ise çıktı değeri hesaplama adımlarını göstermektedir. Şekil 4 sonucunda elde edilen denklemlerin çözülmesi ile

$w_1$  ve  $w_2$  ağırlıklarına ulaşılacak, sonrasında girdi olarak verilen herhangi bir verinin sınıfının tahmin edilmesi sağlanabilecektir.



Şekil 3 (a) Her bir noktanın koordinatı ve XOR fonksiyonu uygulandıktan sonraki sonuç değeri (b) XOR fonksiyonunun  $x_1$  ve  $x_2$  eksenlerindeki grafiksel gösterimi



Şekil 4 (a) RBF uygulama adımları (b) XOR fonksiyonunun  $\phi_1$  ve  $\phi_2$  eksenlerindeki grafiksel gösterimi

x	$\phi_1(x)$	$\phi_2(x)$	d
(1,1)	1	0.135	0
(0,1)	0.367	0.367	1
(0,0)	0.135	1	1
(1,0)	0.367	0.367	0

$$\left. \begin{array}{c} \\ \\ \\ \end{array} \right\} [w_1 \ w_2] * \begin{bmatrix} 1 & 0.367 & 0.135 & 0.367 \\ 0.135 & 0.367 & 1 & 0.367 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \\ 1 \\ 0 \end{bmatrix}$$

Şekil 5 Ağırlıkların bulunmasında kullanılacak denklemlerin elde edilmesi

Ağırlıkları gösteren  $w$  değerine ulaşabilmek için matris çarpımları ve matris tersi alma yöntemi de kullanılabilir. Burada  $\Phi$ , (5) numaralı denklemdeki gibi tanımlanırsa,

$$\Phi = (\phi_1, \phi_2, \dots, \phi_j)^T \quad j = 1, 2, \dots, K \quad (5)$$



Şekil 5'deki denklemde bulunan  $w$  ağırlıklarının bulmak için, (6) numaralı eşitlik oluşturulabilir.

$$\Phi w = d \quad (6)$$

Bu yapı, (7) numaralı denklemdeki gibi yazılabilir.

$$\Phi^T \Phi w = \Phi^T d \quad (7)$$

Sonraki aşamada,  $\Phi^T \Phi$  matrisinin tersi alınarak  $w$  bulunabilir.

Eğer ilgili matrisin tersi alınamıyorsa, sinirsel ağlardaki iteratif yöntemlerden biri kullanılarak  $w$  matrisi elde edilebilir. Melezleştirme aşamasında, gizli katmanların eğitimi için K-means algoritması kullanılmış, çıktı katmanının eğitimi için ise RLS yöntemine başvurulmuştur. Sonuç olarak,  $w$  değerleri iteratif olarak güncellenerek çözüm elde edilecektir.

K-means algoritması hesaplamalarını iteratif bir yöntem ile ilerletir. RLS yöntemi de K-means mantığı ile ilerleyen bir algoritma olduğundan, her iterasyonda bulunan ağırlık değeri ile önceki ağırlık değeri arasındaki fark değerine odaklanarak güncellemeler yapılacaktır. (7) numaralı formülasyonda, (8) numaralı denklemde gösterildiği gibi dönüşümler yapılırsa,

$$\underbrace{\Phi^T \Phi}_{R(n)} w = \underbrace{\Phi^T d}_{r(n)} \quad (8)$$

$$R(n)w(n) = r(n)$$

Bu yapıda,  $w(n)$  ağırlık matrisi ile  $w(n-1)$  ağırlık matrisi arasındaki fark bulunmaya çalışılacağından,  $r(n)$ ,  $r(n-1)$  ile bağıntılı yazılacaktır. Buna göre, (9) numaralı eşitlik ortaya çıkmaktadır.

$$\begin{aligned} r(n) &= \sum_{i=1}^{n-1} (\Phi(x_i)d(i)) + \Phi(x_n)d(n) \\ &= r(n-1) + \Phi(x_n)d(n) \\ &= R(n-1)w(n-1) + \Phi(x_n)d(n) \end{aligned} \quad (9)$$

Bu denkleme  $\Phi(n)\Phi^T(n)w(n-1)$  ekleyip çıkarılırsa, (10) numaralı eşitlik elde edilecektir.

$$r(n) = w(n-1) \underbrace{[R(n-1) + \Phi(n)\Phi^T(n)]}_{R(n)} + \Phi(n) \underbrace{[d(n) - \Phi^T(n)w(n-1)]}_{\substack{d(n) - w^T(n-1)\Phi(n) \\ \alpha: \text{Önceki tahmin}}} \quad (10)$$

$r(n)$  yerine  $R(n)w(n)$  yazılarak denklem sadeleştirilirse (11) numaralı eşitlik elde edilir.

$$R(n)w(n) = R(n) * w(n-1) + \Phi(n)\alpha(n) \quad (11)$$

Her iki taraf  $R^{-1}(n)$  ile çarpılırsa, (12) numaralı eşitlikte de görülebileceği gibi  $w(n)$  değerine ulaşılabilir.

$$w(n) = w(n-1) + R^{-1}(n)\Phi(n)\alpha(n) \quad (12)$$

Sonuç olarak, ağırlıklar arası fark (13) numaralı denklemde gösterildiği gibi yazılabilir. Denklemde,  $\alpha(n)$ , önceki tahmin olduğuna göre, ağırlık vektörleri arası fark, kazanç matrisi ve önceki tahmin çarpımı ile bulunabilir.

$$\Delta w = \underbrace{R^{-1}(n)\Phi(n)}_{\text{Kazanç matrisi}} \alpha(n) \quad (13)$$

(13) numaralı eşitlikteki  $R^{-1}(n)$  matrisinin bulunması için, matris tersi alma teoremi (matrix inversion lemma) gereğince, (14) numaralı eşitlik yazılabilir.

$$R(n) = R(n-1) + \Phi(n)1\Phi^T(n) \quad (14)$$

(14) numaralı eşitlikteki  $R(n)$  matrisinin tersi (15) denkleminde gösterildiği gibi bulunabilir.

$$R^{-1}(n) = R^{-1}(n-1) - \frac{R^{-1}(n-1)\Phi(n)\Phi^T(n)R^{-1}(n-1)}{1 + \Phi(n)R^{-1}(n-1)\Phi(n)} \quad (15)$$

Algoritmayı başlatmak için;

$w(0)=0$  ve  $R^{-1}(0) = \lambda^{-1} * I$  ataması yapılabilir.  $I$  birim matris olup,  $\lambda$  değerinin küçük seçilmesi eğitim örnekleme kalitesinin güvenilirliğini sağlayacaktır.

Matlab R2013a ortamında kodlanan algoritma ile elde edilen sonuçların karşılaştırılması sonraki bölümde detaylandırılmıştır.

## 5. İPLİK KALİTE KABUL SÜRECİNE UYGULAMA VE SONUÇLARIN KARŞILAŞTIRILMASI (IMPLEMENTATION ON YARN INCOMING QUALITY CONTROL PROCESS AND COMPARISON OF RESULTS)

Bu bölümde, Bursa'da döşemelik kumaş üreten bir firmaya ait iplik kalite kabul süreci incelenmiştir. İplik kabul sürecinde dikkate alınan 4 adet parametre bulunmaktadır Bunlar, dayanıklılık, burulma, lif sayısı ve renk farklılığını gösteren Delta E parametreleridir. Bahsi geçen parametreler dikkate alınarak, ilaveten uzman personelin görüşleri nezaretinde iplik kabul işlemleri yapılır. Temelde, hem süreci hızlandırmak, hem de karar verici kişiye yardımcı olacak bir destek sistemi tasarlamak hedeflenmiştir. Bahsi geçen problemde 1231 veri dikkate alınmıştır. Tablo 1, kullanılan veri setinden bir kesiti göstermektedir. Son sütundaki 1 değeri iplik lotunun giriş kabulünü aldığını, -1 değeri ise reddedilen iplik lotu olduğunu göstermektedir.

Tablo 1: İplik kabulü probleminde dikkate alınan veri seti kesiti

Lot No:	Dayanıklılık	Burulma	Lif Sayısı	Delta E	Sonuç
1	10.22	942.00	3.90	0.82	1
2	10.65	947.00	4.00	0.95	-1
3	10.65	942.00	3.90	0.78	1
4	11.25	936.00	3.80	0.89	1
5	10.66	957.00	4.00	0.80	1
6	10.66	948.00	4.00	0.78	1
7	11.20	946.00	4.00	0.80	1
8	10.56	938.00	3.80	0.71	1
9	11.66	942.00	4.00	1.37	-1
...	...	...	...	...	...
1226	11.33	942.00	3.80	0.77	-1
1227	10.65	942.00	3.80	0.77	1
1228	11.00	945.00	4.00	0.85	1
1229	10.69	943.00	3.90	0.82	1
1230	10.88	948.00	3.90	0.76	-1
1231	10.69	942.00	3.80	0.75	-1

Melez genetik algoritma parametre seçimleri, deneysel tasarım ile yapılmış, analizler tamamlandığında en iyi sonuçlara, popülasyon sayısı 100, çaprazlama oranı ve mutasyon oranı değerleri için sırasıyla 1 ve 0.5 değerleri kullanıldığında ulaşılabilmektedir. Algoritmada da anlatıldığı gibi, değişken  $k$  içeren  $k$ -NN sınıflandırıcısı kromozoma entegre edilmiştir. Melez RBF için ise, gizli katman (K) sayısı 24 olarak belirlenmiş, K-means algoritması ile orta noktaların hangi örnekler olduğuna karar verilmiştir. Melez genetik algoritma C# programlama dilinde, melez RBF Matlab R2013a ortamında kodlanmış ve 2.10 GHz hızında çalışan Intel Core i7-3612QM işlemcili bilgisayarda çalıştırılmışlardır. İlave olarak, Naive Bayes [39] ve IBk [40] sınıflandırma algoritmalarının performansları da Weka veri madenciliği yazılımı [41] kullanılarak elde edilmiştir. Weka, algoritma karşılaştırmaları için sıklıkla başvurulan [42] bir açık kaynak yazılımıdır. Tablo 2, bahsi geçen algoritmalar ile elde edilen sınıflandırma doğruluk oranı değerlerini karşılaştırmaktadır. Değerler, 10-katlı çapraz doğrulamadaki her katın 10 farklı çekirdek değeri ile tekrarlanması sonucunda elde edilen 100 doğruluk oranının ortalaması olup, Tablo 2'ye göre melez genetik algoritma ve melez RBF sonuçlarının birbirine oldukça yakın olduğu gözlemlenebilir.

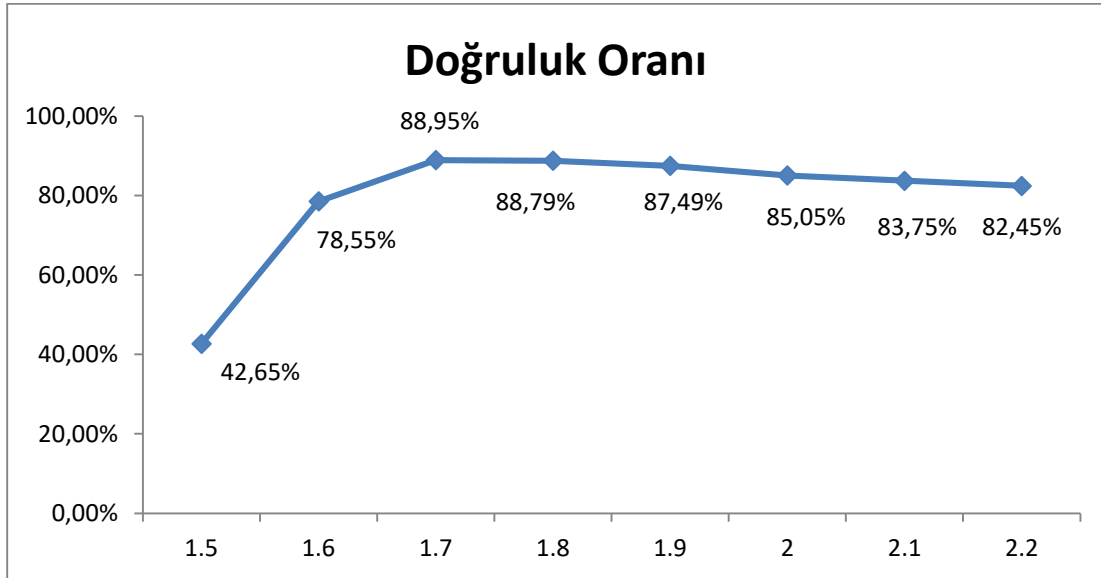
Tablo 2: Metotların sınıflandırma performanslarının karşılaştırılması

Metod	Ortalama Doğruluk Oranı (%)
Melez RBF	90.25
Melez genetik algoritma	90.14
Naive Bayes	87.11
IBk	82.57

Melez genetik algoritmanın problem için sergilediği performans seviyesi gözlemlendikten sonra, firmanın kalite kabul aşamasında daha hızlı karar verebilmesini desteklemek için genetik algoritma seçeneğine odaklanılmıştır. Daha önce de anlatıldığı gibi, melez genetik algoritma,  $k$ -NN mantığı ile ilerleyip sonucu tahmin etmek istediği örneği en yakın  $k$  adet komşusunda en sık görülen sınıf etiketi ile sınıflandırmaktadır. Elde edilen modelin (en iyi kromozom) kabul aşamasında daha etkin kullanılabilmesi için ise seçilen özneliklerin ve en iyi kromozomdaki katsayılarının doğrudan kullanılması sağlanmıştır. Tablo 3, yapılan çalışmaları özetlemek için kullanılabilir. Melez genetik algoritmanın en iyi olarak seçtiği kromozomda birinci (Dayanıklılık) ve dördüncü (Delta E) öznelikler sınıflandırma için kullanılmış ve ağırlıkları sırasıyla 0.1 ve 0.58 olarak belirlemiştir. Burulma ve Lif Sayısı öznelikleri kromozom tarafından seçilmediği için Tablo 3'de üçüncü ve dördüncü sütunlar gri ile gösterilmiştir ve kabul kararında kullanılmamıştır. Tablo 3'ün altıncı sütununda da gösterildiği gibi, öznelik değerleri ile ağırlıklarının çarpılması ile elde edilen sonuçların toplamı, model hesap değeri olarak tanımlanmıştır. Tüm verilerin model hesap değeri, 1. ve 4. özneliklerin her birine ait değerin belirlenen katsayıları ile çarpılması ve çarpım sonuçlarının toplanmasının ardından elde edilmiş ve bu sonuçlar bir skalada değerlendirilmiştir. Sonuçların 1.30 - 3.85 aralığında dağıldığı, en sık gözlemlenen rakamların ise 1.5 - 2.2 aralığında olduğu gözlemlenmiştir. Sonrasında, 1.5 ile 2.2 aralığında 0.1 ilerleyerek elde edilen her bir değerin eşik değeri seçilmesi sonucundaki doğruluk oranı hesaplanmış ve grafiği, Şekil 6'daki gibi oluşturulmuştur. Şekil 6'daki grafiğe göre en yüksek doğruluk oranı olan % 88.95 değeri, 1.7 eşik değeri kullanılarak elde edilmiştir. Tablo 3'ün yedinci sütunda, model hesap değeri, en yüksek doğruluk oranını veren 1.7 eşik değeri ile karşılaştırılarak kabul ya da ret kararı ile ilgili bir tahmin yapılmaktadır. Son sütun ise gerçek kabul (1) ya da ret (-1) kararını göstermektedir. Elde edilen doğruluk oranı, Tablo 2'deki, melez genetik algoritma ortalama değeri olan % 90.14 değerine yakın olduğundan bahsi geçen katsayılar bir öngörü olarak kabul-ret karar aşamasında destek olarak kullanılabilir. Yapılan çalışmayı doğrulamak için, esinlenen yöntem olan regresyondaki doğruluk oranı performansı ise Weka [41] ile hesaplanmış ve %64.53 değeri hesaplanmıştır. Önerilen yöntem, belirgin bir farkla daha iyi performans sergilemiştir. Bununla birlikte, ilgili değerlerin belirli frekanslarla güncellenmesi, verilen kararın doğruluk oranının ortalama seviyelerde kalmasını destekleyecektir.

Tablo 3: Öznitelik katsayılarına göre kabul ret kararı

Lot No	Dayanıklılık	Burulma	Lif Sayısı	Delta E	Model hesap : Dayanıklılık * 0.1+ Delta E * 0.58	Tahmin : Model Hesap ≤ 1.7 ; 1 > 1.7 ; -1	Sonuç
1	10.22	942.00	3.90	0.82	1.50	1	1
2	10.65	947.00	4.00	0.95	1.62	1	-1
3	10.65	942.00	3.90	0.78	1.52	1	1
4	11.25	936.00	3.80	0.89	1.64	1	1
5	10.66	957.00	4.00	0.80	1.53	1	1
6	10.66	948.00	4.00	0.78	1.52	1	1
7	11.20	946.00	4.00	0.80	1.58	1	1
8	10.56	938.00	3.80	0.71	1.47	1	1
9	11.66	942.00	4.00	1.37	1.96	-1	-1
...	...	...	...	...	...	...	...
1226	11.33	942.00	3.80	0.77	1.58	1	-1
1227	10.65	942.00	3.80	0.77	1.51	1	1
1228	11.00	945.00	4.00	0.85	1.59	1	1
1229	10.69	943.00	3.90	0.82	1.54	1	1
1230	10.88	948.00	3.90	0.76	1.53	1	-1
1231	10.69	942.00	3.80	0.75	1.50	1	-1



Şekil 6 Farklı değerlere göre doğruluk oranlarının karşılaştırılması

## 6.SONUÇ (CONCLUSION)

Yapılan çalışmanın amacı, gerçek üretim ortamının giriş kalite kontrol aşamasında, iplik kabul kararının verilmesini destekleyecek bir öngörü karar destek modelinin kurulmasıdır. Bu amaçla, daha önce, öznitelik seçimi ve sınıflandırma ile ilgili problemlerin çözümü için önerilen ve performansı doğrulanan melez genetik algoritma, C# programlama dilinde probleme adapte edilmiştir. Eşzamanlı öznitelik seçim ve ağırlıklandırması yapan, değişken k politikası içeren k-NN sınıflandırıcısının ve lokal aramanın genetik algoritmanın içerisine gömüldüğü melez yapı bu makalede ilk kez sinirsel ağlar ile karşılaştırılmıştır. Sinirsel ağlar kapsamında, RLS süzgeci ile melezleştirilen RBF ve RLS algoritma adımları detaylı olarak

tanımlanmış ve Matlab R2013a'da kodlanmıştır. Uygulama sürecinde ise öncelikle iplik kalite kabul aşamasında kabul ya da ret kararını etkileyen parametreler ve örnek sayısı ile ilgili problem kapsamı hakkında bilgilendirme yapılmıştır. Geliştirilen melez genetik algoritma ve melez RBF algoritmalarının dışında, Naive Bayes ve IBk algoritmalarının sınıflandırma performansları da ölçülmüş ve dört adet algoritmanın sonuçları karşılaştırılmıştır. Karşılaştırılan değerler, her bir algoritmanın 10-katlı çapraz doğrulamasının her katının 10 kez tekrarlanarak elde edildiği 100 adet sonucun ortalamasıdır. Ortalama %90.14 doğruluk oranı ile melez genetik algoritma, %90.25 doğruluk oranı hesaplanan melez RBF algoritması ile yakın değer elde edebilmiştir. Önerilen melez genetik algoritmanın en iyi kromozomunun yapısından hem önemli öznelikler hem de bunların katsayıları doğrudan alınabildiği için, performansı doğrulanmış olan genetik algoritma ile kabul kararı öngörü sistemi üzerinde çalışılmıştır. Eldeki tüm veriler kullanılarak, en iyi kromozomun seçtiği birinci ve dördüncü özneliklerin değerleri ve katsayıları çarpılıp toplanarak, ve sonrasında belirlenen eşik değeri ile karşılaştırılarak kabul ya da ret kararının verilmesi durumunda %88.95 doğruluk oranı tespit edilmiştir. Yöntemin, iplik kabul aşamasında kullanımı ile kararların daha hızlı şekilde verilebileceği bir öngörü sistemi geliştirilmiştir. Önerilen yöntem, ilham alınan metot olan regresyon ile de karşılaştırılmış ve önerilen yöntemin belirgin bir farkla daha iyi performans sergilediği gözlemlenmiştir.

Sonraki çalışmalar, öznelik sayısının daha fazla olduğu, nümerik değerlerin yanında kategorik verilerin de olduğu veri setleri de dikkate alınarak yapılabilir. İlaveten daha yüksek doğruluk oranı değerlerini veren algoritmaların geliştirilmesine de odaklanılabilir.

#### **KAYNAKLAR (REFERENCES)**

- [1] H. Hillaker, John Boyd, USAF Retired, Father of the F-16, Code One: An Airpower Projection Magazine, (1997).
- [2] D. Galinec , W. Steingartner, A look at observe, orient, decide and act feedback loop, pattern-based strategy and network enabled capability for organizations adapting to change, Acta Electrotechnica et Informatica, 13(2) (39), (2013).
- [3] W. Ni, A review and comparative study on univariate feature selection techniques (Doctoral dissertation, University of Cincinnati) (2012).
- [4] Y. Saeys, I. Inza , P. Larrañaga, A review of feature selection techniques in bioinformatics, Bioinformatics, 23(19) (2007) 2507-2517.
- [5] J. R. Vergara, P.A. Estévez, A review of feature selection methods based on mutual information, Neural computing and Applications, 24(1) (2014) 175-186.
- [6] M. Seera, C.P. Lim, A hybrid intelligent system for medical data classification, Expert Systems with Applications, 41(5) (2014) 2239-2249.
- [7] K. Bache, M. Lichman, UCI Machine Learning Repository [http://archive.ics.uci.edu/ml]. Irvine, CA: University of California, School of information and computer science, 28, (2013).
- [8] Y. Marinakis, M. Marinaki, A hybridized particle swarm optimization with expanding neighborhood topology for the feature selection problem, In International Workshop on Hybrid Metaheuristics, Springer, Berlin, Heidelberg (2013) 37-51.
- [9] S. Chatterjee, A. Bhattacharjee, Genetic algorithms for feature selection of image analysis-based quality monitoring model: An application to an iron mine, Engineering applications of artificial intelligence, 24(5) (2011) 786-795.
- [10] C. F. Tsai, W. Eberle, C.Y. Chu, Genetic algorithms in feature and instance selection, Knowledge-Based Systems, 39 (2013) 240-247.
- [11] N. Das, R. Sarkar, S. Basu, M. Kundu, M. Nasipuri, D.K. Basu, A genetic algorithm based region sampling for selection of local features in handwritten digit recognition application, Applied Soft Computing, 12(5) (2012) 1592-1606.

- [12] H. Du, *Data Mining Techniques and Applications: an introduction*, Cengage Learning EMEA (2010).
- [13] T. Sousa, A. Silva, A. Neves, Particle swarm based data mining algorithms for classification tasks, *Parallel Computing*, 30(5-6) (2004) 767-783.
- [14] M. Zhao, C. Fu, L. Ji, K. Tang, M. Zhou, Feature selection and parameter optimization for support vector machines: A new approach based on genetic algorithm with feature chromosomes, *Expert Systems with Applications*, 38(5) (2011) 5197-5204.
- [15] S. Li, H. Wu, D. Wan, J. Zhu, An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine, *Knowledge-Based Systems*, 24(1) (2011) 40-48.
- [16] A. Özçift, A. Gülten, Genetic algorithm wrapped Bayesian network feature selection applied to differential diagnosis of erythematous-squamous diseases, *Digital Signal Processing*, 23(1) (2013) 230-237.
- [17] S. S. Haykin, *Neural networks and learning machines (Vol. 3)*. Upper Saddle River: Pearson. (2009).
- [18] J. X. Du, C.M. Zhai, A hybrid learning algorithm combined with generalized rls approach for radial basis function neural networks, *Applied Mathematics and Computation*, 205(2) (2008) 908-915.
- [19] Y. J. Oyang, S.C. Hwang, Y.Y. Ou, C.Y. Chen, Z.W. Chen, Data classification with radial basis function networks based on a novel kernel density estimation algorithm, *IEEE transactions on neural networks*, 16(1) (2005) 225-236.
- [20] D. S. Huang, Application of generalized radial basis function networks to recognition of radar targets, *International Journal of Pattern Recognition and Artificial Intelligence*, 13(06), (1999) 945-962.
- [21] X. Fu, L. Wang, Data dimensionality reduction with application to simplifying RBF network structure and improving classification performance, *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 33(3) (2003) 399-409.
- [22] P. Janik, T. Lobos, Automated classification of power-quality disturbances using SVM and RBF networks, *IEEE Transactions on Power Delivery*, 21(3) (2006) 1663-1669.
- [23] V. Gümüş, M.E. Kavşut, Zamanti Nehri-Ergenusağı İstasyonu Eksik Aylık Akım Verilerinin Tahmini, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*.1(2) (2013) 81-91.
- [24] P. Yildirim, D. Birant, T. Alpyildiz, Data mining and machine learning in textile industry, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(1):e1228, (2018).
- [25] U. Akyol, P. Tüfekci, K. Kahveci, A. Cihan, A model for predicting drying time period of wool yarn bobbins using computational intelligence techniques, *Textile Research Journal*, 85(13) (2015) 1367-1380.
- [26] Z. Yildiz, V. Dal, M. Ünal, K. Yildiz, Use of artificial neural networks for modelling of seam strength and elongation at break, *Fibres & Textiles in Eastern Europe*, (2013).
- [27] B. K. Behera, B. Karthikeyan, Artificial neural network-embedded expert system for the design of canopy fabrics, *Journal of Industrial Textiles*, 36(2) (2006) 111-123.
- [28] D. Nurwaha, X.H. Wang, Using intelligent control systems to predict textile yarn quality, *Fibres & Textiles in Eastern Europe*, 20(1) (2012) 23-27.
- [29] N. A. Kotb, Predicting yarn quality performance based on fibers types and yarn structure, *Life Science Journal*, 9(3) (2012) 1009-1015.
- [30] K. A. Abakar, C. Yu, The performance of data mining techniques in prediction of yarn quality, *International Journal of Innovation, Management and Technology*, 4(4) (2013) 390.

- [31] M. Amin, M. A. Ullah, A. Akbar, Identification of cotton properties to improve yarn count quality by using regression analysis, *Pakistan Journal of Scientific & Industrial Research Series A: Physical Sciences*, 57(3) (2014) 167-171.
- [32] A. Raggi, G. Barbiroli, Colour difference measurement: The sensitivity of various instruments compared, *Color Research & Application*, 18(1) (1993) 11-27.
- [33] H. C. Lien, S. Lee, Applications of neural networks for grading textile yarns, *Neural Computing & Applications*, 13(3) (2004) 185-192.
- [34] M. Krifa, M.D. Ethridge, Compact spinning effect on cotton yarn quality: Interactions with fiber characteristics, *Textile Research Journal*, 76(5) (2006) 388-399.
- [35] M. A. Tahir, A. Bouridane, F. Kurugollu, Simultaneous feature selection and feature weighting using Hybrid Tabu Search/K-nearest neighbor classifier, *Pattern Recognition Letters*, 28(4) (2007) 438-446.
- [36] D. Y. Eroglu, K. Kilic, A novel Hybrid Genetic Local Search Algorithm for feature selection and weighting with an application in strategic decision making in innovation management, *Information Sciences*, 405 (2017) 18-32.
- [37] M. R. Alam, R. Togneri, F. Sohel, M. Bennamoun, I. Naseem, Linear regression-based classifier for audio visual person identification, In 2013 1st International Conference on Communications, Signal Processing, and their Applications (ICCSPA) IEEE, (1-5) (2013).
- [38] P. Bühlmann, B. Yu, Boosting with the L 2 loss: regression and classification, *Journal of the American Statistical Association*, 98(462) (2003) 324-39.
- [39] G. H. John, P. Langley, Estimating continuous distributions in Bayesian classifiers, In Proceedings of the Eleventh conference on Uncertainty in artificial intelligence, (338-345). Morgan Kaufmann Publishers Inc., (1995).
- [40] D. W. Aha, D. Kibler, M. K. Albert, Instance-based learning algorithms, *Machine learning*, 6(1) (1991) 37-66.
- [41] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, I.H. Witten, The WEKA data mining software: an update, *ACM SIGKDD explorations newsletter*, 11(1) (2009) 10-18.
- [42] M. Gök, Makine öğrenmesi yöntemleri ile akademik başarının tahmin edilmesi, *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 5(3) (2017) 139-148.