

20
19

GELECEĞİN DÜNYASINDA BİLİMSEL VE MESLEKİ ÇALIŞMALAR

BİLGİSAYAR MÜHENDİSLİĞİ

EDİTÖRLER

DR. ÖĞR. ÜYESİ ABDULLAH ELEN

DR. ÖĞR. ÜYESİ EMRE AVUÇLU

EKİN 
Basım Yayın Dağıtım

**GELECEĞİN DÜNYASINDA
BİLİMSEL VE MESLEKİ ÇALIŞMALAR
2019
BİLGİSAYAR MÜHENDİSLİĞİ**

EDİTÖRLER

DR. ÖĞR. ÜYESİ ABDULLAH ELEN
DR. ÖĞR. ÜYESİ EMRE AVUÇLU

EKİM 2019
BURSA / TÜRKİYE

EKİN 
Basım Yayın Dağıtım

Editörler

DR. ÖĞR. ÜYESİ ABDULLAH ELEN

DR. ÖĞR. ÜYESİ EMRE AVUÇLU

Birinci Baskı • © Ekim 2019 / Bursa

ISBN • 978-605-327-985-3

© copyright

All Rights Reserved

Ekin Basım Yayın Dağıtım

Tel: 0224 223 04 37

Mail: info@ekinyayinevi.com

Web: www.ekinyayinevi.com

**Adres: Şhreküstü Mahallesi Cumhuriyet Caddesi
Durak Sokak No:2 Osmangazi - Bursa**

EKİN 
Basım Yayın Dağıtım

İÇİNDEKİLER

İÇİNDEKİLER.....	i
GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ.....	1
1. GİRİŞ.....	1
2. GENETİK ALGORİTMA	1
2.1. Genetik algoritmaların tarihçesi.....	2
2.2. Genetik algoritmanın parametreleri	3
2.3. Genetik Operatörler	3
2.4. GA'nın Çalışma Prensipleri	4
2.5. GA'nın Performansını Etkileyen Nedenler	5
2.6. GA'nın Uygulama Alanları	6
2.7. GA ile İlgili Yapılan Çalışmalar	7
3. MATERYAL VE METOT.....	8
3.1. Tek Noktalı Çaprazlama.....	9
3.2. İki Noktalı Çaprazlama	10
3.3. Tekdüze (<i>Uniform</i>) Çaprazlama	10
3.4. Kısmen Uyumlu Çaprazlama (PMX).....	11
3.5. Sıralı Çaprazlama (OX).....	12
3.6. Sıraya Dayalı Çaprazlama (OX2)	13
3.7. Dairesel Çaprazlama (CX)	14
3.8. Konuma Dayalı Çaprazlama (POS).....	14
3.9. Sezgisel Çaprazlama (<i>Heuristic Crossover</i>).....	15
3.10. Maksimal Koruyucu Çaprazlama (<i>Maximal Preservative Crossover-MPX</i>).....	15
4. SONUÇLAR	16
5. KAYNAKÇA	16
İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI	19
1. GİRİŞ.....	19
2. KALİTE KAVRAMI.....	19
2.1. Kalitenin Tanımı.....	20
2.2. Kalitenin Boyutları.....	21
3. KALİTE KONTROL KAVRAMI.....	22
3.1. Kalite Kontrolün Tanımı	22
3.2. Kalite Kontrolün Tarihsel Gelişimi.....	22
3.3. Kalite Kontrolün Amaçları	23
3.4. Kalitenin Yedi Aracı	23

4. KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI.....	24
4.1. Veri girişi.....	24
4.2. Varlık İlişki Diyagramı	27
4.3. Kullanıcı Arayüzü.....	27
5. SONUÇ VE DEĞERLENDİRME	34
6. KAYNAKÇA	35
PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?	36
1. GİRİŞ.....	36
2. ÇOCUKLARIN DOĞASI	36
2.1. Çocukları Anlamak	36
2.2. Peki Ne Yapılabilir?.....	36
2.3. Yöntem.....	36
3. PROGRAM.....	36
3.1. Nasıl Kullanılır?.....	36
3.2. Nasıl Yazıldı?	43
3.3. Nasıl Geri Bildirimler Alındı?	48
4. SONUÇLAR	48
5. KAYNAKÇA	48
TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER...50	50
1. GİRİŞ.....	50
2. TEKNOLOJİK GELİŞMELER.....	51
2.1. Üretimdeki Teknolojik Gelişmeler	51
2.2. Ürünlerdeki Teknolojik Gelişmeler	58
3. SONUÇLAR	63
4. KAYNAKÇA	64
BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ	65
1. GİRİŞ.....	65
2. VERİ MADENCİLİĞİ.....	65
2.1. Sağlık Alanında Veri Madenciliği Kullanımı.....	67
2.2. Kümeleme	68
3. ARAŞTIRMADA KULLANILAN YÖNTEMLER.....	69
3.1. K-means	69
3.2. X-means	73
4. ARAŞTIRMADA KULLANILAN VERİ SETİ	75
5. BULGULAR VE DEĞERLENDİRME.....	75
6. SONUÇ.....	78

7. KAYNAKÇA.....	78
RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ.....	84
1. GİRİŞ.....	84
2. VERİ MADENCİLİĞİ.....	87
2.1. Sağlık Alanında Veri Madenciliği Kullanımı.....	90
3. ARAŞTIRMADA KULLANILAN YÖNTEM.....	92
3.1. Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı.....	92
4. BULGULAR VE DEĞERLENDİRME.....	96
5. SONUÇ.....	97
6. KAYNAKÇA.....	98
YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ.....	104
1. GİRİŞ.....	104
2. CİLT KANSERİ.....	105
3. YAPAY SİNİR AĞLARI.....	107
4. YÖNTEM.....	109
4.1. Bulgular.....	110
5. SONUÇLAR.....	112
6. KAYNAKÇA.....	113
BULANIK MANTIK TEMELLİ BİREYSEL KREDİ BAŞVURUSU DEĞERLENDİRME SİSTEMİ TASARIMI.....	115
1. GİRİŞ.....	115
2. BİREYSEL KREDİLER.....	116
3. BULANIK MANTIK.....	117
4. YÖNTEM.....	118
5. SONUÇLAR.....	122
6. KAYNAKÇA.....	122

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

Abdullah Elen^{1*}, Emre Avuçlu²

¹Karabük University, Vocational School of T.O.B.B. Tech. Sci., Department of Computer Tech.

aelen@karabuk.edu.tr

²Aksaray University, Vocational School of Tech. Sci., Department of Computer Tech.

emreavuculu@aksaray.edu.tr

1. GİRİŞ

Genetik algoritmaların (GA) temeli Darwin'in doğal seçim ve evrim ilkelerine dayanır. Bu anlamda GA oluşturulan popülasyonda bulunan ve bu popülasyonun algoritmasında bulunan bireylerden güçlü olanlar kullanıp yeni ve daha güçlü bireyler topluluğunu oluşturmaktır. Topluluktaki en iyi bireyler hayatta kalır ve iyi bireylerin özelliklerini taşıyan daha iyi bireyler oluşturulması hedeflenmektedir. Genetik algoritmalar; problem için tek bir çözüm üretmeden ziyade birden fazla çözüm üreterek daha geniş bir çözüm havuzu oluşturarak daha etkin bir sonuç elde etmektedir [1]. GA her biri bir çözümü temsil eden bireylerden oluşan bir topluluk üzerinde çalışır. Bu bireylerin oluşturduğu topluluğa popülasyon denir. Algoritmanın her adımda var olan popülasyondan daha iyi bir popülasyon üretmeyi amaçlamaktadır. Genetik algoritmada her bir adım veya başka ifadeyle iterasyon, bir popülasyondan yeni bir popülasyonun oluşturulmasına kadar geçen süreci içerir [2].

Evrimsel Algoritmalar (EA) olarak da ifade edilen GA, doğadaki evrimsel süreçleri model olarak kullanan bilgisayara dayalı problem çözme tekniği olarak tanımlanabilir. Geleneksel programlama yöntemleri ile çözülmesi zor olan, özellikle çok boyutlu optimizasyon ve sınıflandırma problemleri daha kolay ve daha hızlı çözülebilir. GA, çok fazla teorik bilgiye ihtiyaç duymadan uygulanabilir ve bu uygulama sonucu elde edilen verilerin de doğrudan kullanılabilmesi sayesinde yaygın olarak kullanılır. GA, rastgele seçilmiş bireylerden oluşan bir nesille eniyilemeye başlamaktadır. GA'nın amacı; nesildeki zayıf bireyleri ortadan kaldırıp, en güçlünün hayatta kalmasını sağlayacak yeni nesiller oluşturmak için sürekli iyileşen çözümleri bulmaktır. Böylece, nesildeki güçlü bireyler kendilerine eş seçip genlerini çaprazlamaktadırlar. Oluşturulan her yeni nesilde bireyleri oluşturan değişkenlerden herhangi biri veya birkaçı yeniden kopyalama veya mutasyon gibi operatörler kullanılarak farklı bireylere dönüştürülerek yeni bireylerin elde edilmesi sağlanmaktadır. Her yeni nesilde bu işlemler devam etmekte ve bireylerin birbirine benzeme oranı olarak kabul edilen durdurma kriteri sayesinde de algoritmanın çalışması sonlandırılmaktadır [3]. GA metasezgisel yöntemleri kullanarak geleneksel yöntemlerin aksine iyi bir sonuç ele alarak onu geliştirmek yerine çok daha fazla sonucu aynı anda ele alarak algoritmanın daha hızlı çalışmasını sağlar [4].

2. GENETİK ALGORİTMA

GA, doğadaki evrimsel sürece benzeyen bir yöntem ile çalışan arama ve eniyileme yöntemi olarak bilinir. Karmaşık çok boyutlu arama uzayında en iyi bireyin hayatta kalması prensibine göre çalışır ve bütünsel en iyi çözümleri arama mantığına dayanır [5]. GA problemleri çözmek için evrimsel süreci bilgisayar dilinde taklit eder. Diğer eniyileme metodlarının çalışma mantığı gibi, çözüm üretmek için tek bir yapıyı geliştirilmekten ziyade, böyle yapılardan meydana gelen bir küme oluşturulma ilkesine dayanır. Bir problemin çözümü için farklı pek çok çözümü temsil eden bu küme, GA terminolojisinde popülasyon (nüfus) olarak adlandırılır. Popülasyonlarda vektör, birey veya kromozom da denilen sayı dizileri vardır. Bu bireyin içinde bulunan ayrı her bir elemana da gen denilmektedir. Popülasyonun bireyleri evrimsel süreçte GA işlemcileri tarafından belirlenmektedir [5].

Genetik algoritmalarda klasik gradyan-temelli optimizasyon yöntemlerinden farklı olarak, özellikle başlangıçtaki çözüm popülasyonunun yeterli olduğu durumlarda yerel optimuma takılma

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

riski yoktur. Eğri üzerinden rastgele seçilen bir nokta kendisine komşu olan iki noktadan büyüğe yerel maksimum, küçüğe yerel minimum olarak adlandırılmaktadır. Fakat bu nokta tüm fonksiyon içerisindeki maksimum ya da minimum olmayabilir. Tüm değerler arasındaki maksimum ve minimum değerler global maksimum ve global minimum olarak adlandırılmaktadır. Genetik algoritmaların katmanlı kompozit yapıların optimizasyonunda kullanılması oldukça yaygındır. Bunun nedeni çok farklı değişken ve uygunluk fonksiyonlu problemlere kolaylıkla uygulanma olasılığıdır.

Genetik algoritmalar karmaşık çok boyutlu arama uzayında en iyinin hayatta kalması ilkesine göre bütünsel en iyi çözümü arar [5]. Genetik algoritmayı diğer arama yöntemlerinden (tabu arama, benzetilmiş tavlama gibi.) ayıran en belirgin özellikleri çözüm arama şeklinin farklı oluşudur. Aşağıda bu farklılıklar açıklanmaktadır [6].

1. GA, parametrelerin kendisiyle değil, doğrudan parametre kodlarıyla uğraşır. Parametreler kodlanabildiği sürece çözüm üretir.
2. GA tek bir noktadan değil, popülasyonun büyüklüğü kadar noktadan arama yapar.
3. GA, ne yaptığını değil, nasıl yaptığını bilir. Yani GA önceden elde edilmiş bilgiyi değil, sadece amaç fonksiyonundan elde edilen bilgiyi kullanır.
4. GA'nın uygulamasında kullanılan operatörler rastlantısal yöntemlere dayanır; belirli ve kesin yöntemler kullanmazlar.
5. Genetik algoritmalar türev yerine hedef fonksiyonunun değerini kullanır.

Bunların yanında GA; Arama uzayının karmaşık ve büyük olduğu, eldeki mevcut bilgilerle sınırlı arama uzayında çözüme ulaşmanın zor olduğu, problemin belirli bir matematiksel model ile ifade edilemediği alanlarda etkili ve kullanışlı olmaktadır.

2.1. Genetik algoritmaların tarihçesi

İlk defa 1960'larda psikoloji ve bilgisayar bilimi uzmanı olan John Holland tarafından geliştirilen; kendisi ile birlikte, öğrencileri ve meslektaşları tarafından geliştirilen G.A.'lar, mühendislik dünyasında birçok alanda genişçe işlenmiş, deneyleri yapılmış ve başarılı bir şekilde uygulanmıştır [7]. Bununla birlikte 1975'de G.A.'nın teorik çatısının anlatıldığı John Holland'ın "Doğal ve Yapay Sistemlerde Adaptasyon" (*Adaptation in Natural and Artificial Systems*) isimli kitabı piyasaya çıkmıştır. Mekanik öğrenme (*machine learning*) konusunda çalışan Holland, Darwin'in evrim kuramında etkilenecek canlılarda yaşanan genetik süreci bilgisayar ortamında aktarır çeşitli sonuçlar almayı hedeflemiştir.

Evrimsel algoritmalar arama tekniklerine rastsallık katarak popülasyonların doğal evrim süreçlerini taklit etme mantığına dayanarak çalışır. EA ilk olarak Fogel (1966) evrimsel programlama ve Rechenberg (1973), Schwefel (1975) evrimsel stratejiler olarak sunulmuştur [8]. John Holland doğal evrimden ve canlılardaki bu süreci kullanarak, makine öğrenmesi üzerine çalışmalarını yoğunlaştırmıştır. Holland'ın asıl amacı, belirli problemleri çözmek için algoritma tasarlamak değil; uyum olgusu üzerinde çalışarak doğal uyumun bilgisayar sistemlerinde aktarılması sonucunda kullanılabilmesini sağlamak olmuştur. 1992'de, John Koza GA'yı verilen bazı görevleri gerçekleştirecek programlar geliştirmek amacıyla kullandı. Koza, bu yönetime genetik programlama adını vermiştir [7].

Yapay sistemlerde genetik algoritma, arama amaçlı kullanılmaya başlanmadan önce birçok biyolog genetik sistemlerin simülasyonu için bilgisayarlardan yararlandı. Bu çalışmalara Barricelli (1957, 1962), Fraser (1960, 1962), Martin ve Cockerham (1960) örnek olarak gösterilebilir. Özellikle Fraser'in çalışması modern genetik algoritma yapısına daha uygundur. John Holland tek bir mekanik yapının öğrenme yeteneğini geliştirmek yerine böyle yapılarda oluşan bir topluluğun çoğalma, çiftleşme, mutasyon, vb. farklı genetik işlemlerden geçerek öğrenebilen yeni bireylerin oluştuğunu görmüştür. Çalışmalarının sonucunu açıkladığı kitabının 1975'te yayınlanmasından sonra geliştirdiği yöntemin adı Genetik Algoritmalar olarak yerleşmiştir. John Holland 1975 yılında yeni çocuklar oluşturmak üzere ebeveynlerden gelen bilgi parçacıklarını farklı kombinasyonlarda birleştirerek genetik algoritma tekniğini geliştirmiştir. Bu tekniği de GA ifadesiyle literatüre kazandırmıştır [8].

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

2.2. Genetik algoritmanın parametreleri

GA'da; farklı kurallara uyum sağlayan bir çözüm değeri için gerekli algoritmanın oluşturulması ve kullanılacak parametrelerin tespit edilmesi gerekir. Bu kavramlar ve algoritmadaki gerekli olan parametreler şu şekildedir;

Gen: Yapısında problem ile ilgili en küçük bilgiyi barındıran birim olarak adlandırılabilir. GA'nın programlama yapısındaki bu genin yapıları programcı tarafından tanımlanarak ifade edilir. Genlerin yapısını sadece ikili tabandaki sayıları oluşturabileceği gibi gray, tamsayı, gerçel sayı, farklı sembolik ifadeler de oluşturabilir [9].

Kromozom: Bir veya daha fazla genin yapısının birleşmesiyle, problem çözümü ile ilgili bilgilerin bir bölümünü oluşturan diziler kromozom olarak adlandırılır [10]. GA'da kromozomlar, kullanılacak en önemli parametre olduğu için bilgisayar dilinde iyi bir tanımlama gerektirir.

Popülasyon: Doğal yaşamda popülasyonlar bireylerin bir arada bulunmasıyla oluşur. Olası çözüm bilgilerini içeren bireylerin bir araya gelerek oluşturdukları topluluğa popülasyon denir. Popülasyonda bulunan bireylerin sayısı, çözüme kavuşturulacak problemin yapısına göre, GA'yı planlayacak olan uzman kişi tarafından belirlenir.

2.3. Genetik Operatörler

Genetik operatörler, GA'nın temel birimlerini oluştururlar ve algoritmanın işleyişi sırasında mevcut popülasyonda gerçekleştirilen uygulamalardır. Bu operatörleri, seçme (*selection*) ya da tekrar üreme (*reproduction*) operatörü, çaprazlama (*crossover*) operatörü ve mutasyon (*mutation*) operatörleri olarak söylemek mümkündür. Bunların yanında bir diğer operatörde, kısıtlı eniyileme problemlerinde kullanılan ve probleme özgü olarak geliştirilen operatör olan tamir (*reparation*) operatörüdür [11]. Genetik operatörler, daha iyi özelliklere sahip nesiller üreterek çözüm uzayını genişletir. Standart olarak kullanılan üç farklı operatör vardır [12].

- **Seçim (Selection):** Seçim işlemi, var olan bireyin genetik yapısının herhangi bir değişikliğe uğratılmadan yeni nesile kopyalanması işlemidir. Eski kuşağı yenilemenin farklı yöntemleri bulunur. Bunlar; kuşaksal strateji, en uygun (*elitist*) strateji ve denge durumu stratejisilerdir. Kuşaksal stratejide, mevcut popülasyondaki kromozomlar yavrular ile tamamen yer değiştirir. Popülasyonun en iyi kromozomu da yenilediği için bir sonraki kuşağa aktarılama işlemi gerçekleşmez. En iyi kromozomu geri kazanmak için bu strateji en uygun (elitist) stratejisiyle beraber kullanılmaktadır. En uygun stratejisinde, popülasyondaki en iyi kromozomlar hiçbir zaman yenilenmez. Denge durumu stratejisinde ise, her kuşakta sadece birkaç kromozomu yenileme işlemi gerçekleştirilir.
- **Çaprazlama (Crossover):** Popülasyonda bulunan iki farklı bireyin yapısının rastgele birleştirilmesi ile yeni bireylerin oluşturulması işlemidir. İşlem, ikili dizilerin parçalarının karşılıklı olarak birbirleri ile değişmesi ile gerçekleştirilir. Mevcut en iyi kromozomların özelliklerini birleştirerek daha iyi özelliklere sahip kromozomlar elde etmek için yapılan çaprazlama operatörünün temel parametresi çaprazlama olasılığıdır. Çaprazlama olasılığı parametresi çaprazlamanın hangi sıklıkta yapılacağını belirler [13]. Çaprazlama olasılığı üreme havuzuna girecek kromozomların sayısını belirler. Bu oran yüksek olursa, iyi özellikteki bireylerin yeni popülasyonda bulunma olasılığı azalır. Düşük olması da yeterli sayıda yeni bireyin oluşmasını engel olur [14]. Uygunluk fonksiyonu değerleri aranan kriterlere yakın yani başarılı olan kromozomlardan, bir seçim yöntemi ile seçilirler. Aranan kriterlerden çok uzak olan bireyler ise elenir. Yeni bireylerin ebeveynlerinin kopyası olması olasılığını önlemek için bu bireyler mutasyon işlemine tabi tutulur. Mutasyon ile rast gele bazı genler değişikliğe uğrar, örneğin 1 ise 0 veya 0 ise 1 olurlar. Algoritmada mutasyon oranını yani değişikliğe uğrama oranını programı tasarlayan kişi belirler. Yeni nesiller oluştuğunda gen havuzunun da kalitesi de her iterasyonda artar. İlk başlangıçta havuz içinde birçok başarısız birey bulunmasına rağmen jenerasyon ilerledikçe havuzun çoğunluğu başarılı bireylerden oluşur. En sonunda tüm bireyler istenilen ve aranan ideal bireye dönüşür. Sonuç olarak optimizasyon işlemi hedefine ulaşmış olur [15].

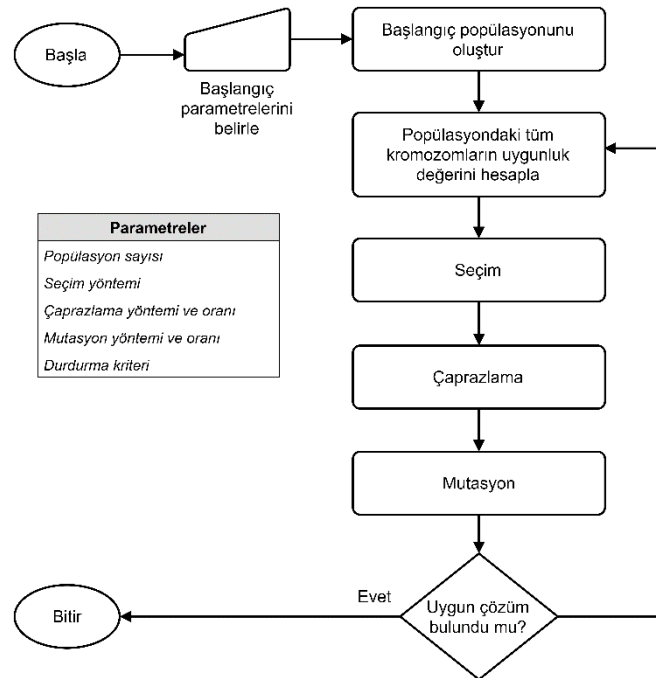
GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

- **Mutasyon (Mutation):** Mutasyon işlemi var olan bir bireyin genlerinin bir ya da birkaçının yerlerinin değiştirilmesi ile gerçekleştirilmektedir. Mutasyonun önemli parametresi, kromozomda ne kadar değişiklik olacağını gösteren mutasyon olasılığıdır. Mutasyon olasılığı 0 olduğunda yeni birey mutasyona uğramadan meydana gelir. %100 olduğunda ise kromozomun yapısı tamamen değişir [13].

2.4. GA'nın Çalışma Prensibi

GA' da oluşturulacak bir popülasyon, çok sayıda bireyin bir araya gelerek, yani çok sayıda olası çözüm adaylarının bir araya gelmesi ile oluşur. Olası aday çözümler, probleme uygun şekilde kodlanan dizilerde tutulur. Bu dizideki her bir elemana birey denilir. Bu her birey, arama uzayındaki belirli bir bölgeyi temsil etmektedir.

GA'da başlangıç bireylerini rastgele üretmek mümkündür fakat bu işlem tabi ki zorunluluk teşkil etmez. Özellikle de bir çok kısıtı olan optimizasyon problemlerin çözümünde, başlangıç bireylerini oluşturmak için tanımlanan kısıtların bir kısmına göre yapılan atamalar ile daha iyi adayları oluşturmak mümkün olabilir. Bireyleri, uygunluk fonksiyonuna tabi tutarak, çözümün optimal çözüme ne kadar yaklaştığını değerlendiren bir uygunluk değeri elde edilir. Başlangıç popülasyonu oluşturulan bir GA üç evrim operatörüyle çalışır. Bunlar operatörler; seçim, çaprazlama ve mutasyondur. Genel olarak bu operatörlerin her biri, yeni nesilde oluşan popülasyonun her bireyi için ayrı ayrı uygulanmaktadır. Seçim süreci, popülasyonda bulunan bireyin uygunluk değerine göre, yeni bireyler oluşturmak için, ebeveyn bireyi seçme süreci olarak bilinir. Çaprazlama operatörü ise, seçim işleminden sonra uygulanır. Ebeveyn bireylerinin kromozomlarının belirli kısımlarının karşılıklı olarak yer değiştirmesi sonucunda yeni özelliklere sahip bireyleri oluşturmadan sorumludur. Mutasyon, yeni özellikte oluşan bireylerde kromozomların herhangi birisinin içinde olan geni mutasyon olasılığına göre değiştirilmesidir. Şekil 1'de GA'nın genel akış diyagramı gösterilmektedir.



Şekil 1: GA'nın akış diyagramı.

GA parametresinde tanımlanan popülasyondaki toplam birey sayısı kadar birey olduğunda, yeni bir nesil meydana gelmiş olur. Bu yeni nesil önceki neslin yerini alır. Her nesilde bireylerin temsil ettiği çözüm değerlendirilerek, buldukları popülasyonun en iyi bireyi seçilir. Bulunan en iyi birey, önceki nesillerde bulunan en iyi bireylerden daha iyiyse onun yerine geçer. GA işlemini sonlandırma işlemi için çeşitli metotlar bulunur. Bu metotlar; algoritma çalışmaya devam ederken istenilen çözüm elde edildiğinde, GA'nın başlangıcı esnasında tanımlanmış olan toplam iterasyonun

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

sayısına ulaşıldığında veya uygunluk değerinin devamlı sabit kalması durumunda, bulunan en iyi bireyi temsil eden çözüm, problem için sonuca ulaşılmış en uygun çözüm olarak değerlendirilir.

2.5. GA'nın Performansını Etkileyen Nedenler

GA'nın işleyişini etkileyen faktör parametrelerdir. Genel olarak bu parametreler popülasyon büyüklüğü, mutasyon tipi ve olasılığı, çaprazlama tipi ve olasılığı, nesil sayısı ve seçim operatörünün tipidir. Literatürde, bu parametrelerin uygun değerlerini bulmak için yapılmış teorik veya uygulamaya yönelik pek çok çalışma vardır [9,16]. Genetik algoritmanın performansını etkileyen faktörler aşağıda verildiği gibi sıralanabilir [17];

Kodlama biçimi: GA'nın performansını belirleyen önemli bir faktördür, fakat kodlama biçimi probleme ve programa bağlı olduğu için bütün problemlerde geçerli olan uygun kodlama biçimini söylemek mümkün değildir. Michalewicz belirli bir problem tipi için gerçekleştirdiği çalışmada, gerçel sayı gösteriminin daha çabuk sonuca götürdüğünü söylemiştir [9]. GA yerel en iyi içindeki çözümü bulmak yerine yüksek oranda çoklu arama yeteneği sunarlar. GA uygunluk fonksiyonunun hesaplanması dışında hiçbir karmaşık matematiksel formül içermez ve genetik algoritmalar eniyileme için arama yönünde özel bir kurala sahip değildir [18].

Kromozom sayısı: Kromozomun sayısı arttıkça çalışma zamanı da artmakta, sayıyı azaltma işleminde ise de kromozomların çeşitli olması engellenmektedir. GA'ların ana fikrinde, kromozoma sahip bireylerin karakterize ettiği toplumu yenilemesi fikri yatar. Kromozomları, l uzunluğundaki sembollerin bir zincir oluşturması sonucu oluşan yapı ile ifade etmek mümkündür. Oluşturulmuş olan her bir kromozom, optimizasyon probleminde uygun bir çözüm olarak düşünülür. Sembollerin her biri gen olarak adlandırılmaktadır ve gen hangi parametreyi ifade edecekse sıra ile dizilmesi sonucu kromozomlar oluşturulmuş olur. GA ve optimizasyon probleminin arasında bulunan bağlantıyı uygunluk fonksiyonu (F) sağlar. F fonksiyonu kromozomlar için kullanılır ve onları gerçel sayılara dönüştürmek için kullanılır. F değerinin büyük olması sonucu kromozomun temsil ettiği çözüm diğer kromozomlara göre daha iyidir [19].

Mutasyon oranı: Kromozomların yapısı birbirlerine benzer olmaya başladığı zaman hala çözüm değerlerinin uzağındalarsa, bu durumu mutasyon işlemi ile atlatmak mümkündür. GA'nın çıkmaza girdiği yerden kurtulmak için tek yol olarak da söylenebilir. Ancak yüksek bir değer vermek GA'yı kararlı bir noktaya ulaşmasını zorlaştıracaktır.

Kaç noktalı çaprazlama yapılacağı: Normal olarak çaprazlama tek noktada gerçekleştirilir fakat yapılan araştırmalar bazı problemlerde çok noktalı çaprazlamanın daha fazla yararlı olduğunu göstermiştir.

Parametre kodlanmasının nasıl yapıldığı: GA'da en önemli noktalardan biride kodlama işleminin nasıl yapılacağıdır. Parametrenin doğrusal ya da logaritmik olarak kodlanması GA'nın performansında oldukça önemlidir. Kodlamanın ikilik düzen, kayan nokta aritmetiği veya gray kodu ile gösterimi kodlama gösteriminde en yaygın yöntemlerdir.

Başarı değerlendirmesinin nasıl yapıldığı: Düzgün yazılmayan bir değerlendirme işlevi çalışma zamanını uzatmanın yanında çözüme hiçbir zaman erişememeye de neden olabilir.

Popülasyon büyüklüğü: Popülasyonun büyüklüğü problemin çözüm süresinde etkilidir. Popülasyonda bulunan bireylerin sayısı gereğinden fazla ise çözüm süresi uzar, bireylerin sayısı gereğinden az ise popülasyon istenen çözüme ulaşamayabilir. Problemin yapısına göre popülasyondaki birey sayısı, GA'yı hazırlayan uzman tarafından iyi belirlenmesi gerekir. Grefensette, GA için en uygun popülasyon büyüklüğü 10 ile 160 birey arasında olması gerektiğini savunmuştur [20]. Bunların yanında uygunluk fonksiyonunun ölçeklenmesinde rank, oransal, doğrusal ve üstsel ölçekleme gibi yöntemler mevcuttur. Problemin yapısına göre uygun ölçek seçmek, genetik algoritmanın etkin işlemesi açısından önemlidir [21].

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

2.6. GA'nın Uygulama Alanları

Genetik algoritmanın 1975-1987 yılları arasındaki ilk uygulamalarına bakıldığında çok farklı alanlarda birçok çalışma ile vardır. Günümüzde ise genetik algoritma mühendislik, bilim ve ekonomi gibi birçok farklı alanlardaki problemlerde başarıyla uygulanmıştır.

Biyoloji, mühendislik ve yöneylem araştırması, genetik algoritmanın kendi mekanizması ve parametreleri ile ilgili çalışmalar, hibrit teknikler, görüntü işleme ve örüntü tanımlama, paralel GA uygulamaları, fizik ve sosyal bilimler GA'nin ilk uygulama alanları olarak bilinen kategorileridir. Genetik algoritma tabanlı kümeleme analizi, uyarlanabilir doküman tanımlama, iş-akış programlama, sırt çantası problemi, yüzeylere uygunluğun tespiti için doğrusal olmayan denklemleri çözme, yinelemeli mahkum ikilemi probleminin çözümü, sınıfların ve ders çizelgelerin hazırlanması GA'nin diğer uygulamalarıdır. Genetik algoritma uygulamalarındaki asıl amaç süreçlerin optimize edilmesi ile birlikte belirli kısıtlar altındaki problemlerin çözümünü bulmaktır.

GA, gezgin satıcı probleminde, ekonomi konularından biri olan oyun teorisindeki denge noktalarının bulunmasında ve strateji alternatifleri arasında karar seçiminde, konteynir yükleme optimizasyonunda, atama problemlerinde, su dağıtım sistemlerinin planlanmasında, fabrika yer seçimi tespitinde, pazar karması analizlerinde, veri madenciliğinde ve web madenciliğinde, iş ve makine programlamada, finansal ve yatırım stratejilerinde, stok modellerinin çözümünde, pazarlama ve perakende sektöründe, sepet analizinde, fabrika atık kontrolü süreçlerinde kullanılır. Bunların yanında kara, hava ve deniz ulaşımı ve taşımacılığı ile ilgili optimizasyon problemlerinde, trafik akış problemlerine en uygun çözümlerin aranmasında kullanılır, havayolu personelinin çalışma programının planlanmasında, hastanelerde acilde çalışan doktorların ve hemşirelerin çalışma programlarının belirlenmesinde, doğalgaz boruları ağının optimizasyonunda, terzilerin optimal kumaş kesimlerinde, talep tahminleme alanlarında kullanılmaktadır.

GA mühendislik başlığı altındaki uygulamaları yapay sinir ağlarının eğitimi, kablosuz algılayıcılar, elektronik devre tasarımında, kontrol mühendisliğinde, bilgisayar sunucu ve ağ sistemlerinin oluşturulmasında, bilgisayarlarla otomasyon tasarımında, güç elektroniği tasarımında, kalite kontrolde, yapay sinir ağlarının eğitilmesinde, kablosuz sensörlerin ve ağların optimum konumlandırılmasında, otomotiv sektöründe yaygın olarak kullanılır. Ayrıca binaların, fabrikaların, makinelerin etkin kullanımları için malzemelerinin ve yapılarının optimizasyonunda, uzay mekiklerinin kalkış süreçlerinin tasarımında, robot teknolojilerinde, paralel hibrit elektrikli araçlarda kontrol stratejilerini optimize etmek için kullanılır.

Genetik algoritma mühendislik, bilim ve ekonomi gibi çok değişik alanlardaki problemlerde başarıyla uygulanmıştır. Bu çalışmalara; gezgin satıcı, yerleşim, atölye çizelgeleme, ders/sınav çizelgelemesi problemlerinin çözümünü örnek gösterebiliriz. Son yıllarda genetik algoritma, optimizasyon problemlerinin çözümü için büyük önem kazanmıştır. Genetik algoritmanın çalışmaları arasında haberleşme şebekeleri tasarımı, elektronik devre tasarımı, gaz boruları şebeke optimizasyonu, görüntü ve ses tanıma, veri tabanı sorgulama optimizasyonu, uçak tasarımı bulunmaktadır [22].

GA'nın bilgisayar teknolojileri ve iletişim teknolojileri başlığı altındaki uygulamalarında, LAN performanslarının artırılmasında, iletişim teknolojilerindeki rotalama optimizasyonunda, kriptolama ve kod kırma yazılımlarında, arama motoru optimizasyonlarında, bilgisayarda oyun teknolojilerinde ve yapay zekâ uygulamalarında sıklıkla başvurulan bir yöntem olmuştur.

Genetik algoritma temel yapısını biyolojiden almaktadır. Aynı zamanda biyolojik gelişmelere hizmet vermektedir. Çaprazlama ve mutasyon yapısından yararlanılarak biyolojik yeni yapıların test edilmesi ve benzetiminde, bilgisayar destekli kimyasal moleküllerin tasarımda ve proteinlerin karmaşık üç boyutlu yapılarının kodlarının çözülmesinde, ilaç sektöründe bu proteinlerin işlevlerini yapabilecek ürünlerin üretilmesinde ve hangi genlerin hangi hastalıklarda etkili olduğunu bulma işlemlerinde kullanılır. Bu uygulamalar ek olarak GA yapay sinir ağları, parçacık sürü optimizasyonu, tabu arama vb. sezgisel yöntemlerle hibrit yapıda kullanılarak arama performansını arttırmak için kullanılır.

2.7. GA ile İlgili Yapılan Çalışmalar

Bu konu üzerine 1960'lı yıllardan bu yana farklı çalışmalar yapılmaktadır. Bu konuda yapılan çalışmaları üç grup altında toplamak mümkündür. Bunlar yapay zeka, insan makine etkileşimi ve yöneylem araştırmasıdır. Yapay zeka olarak kısıt programlama, uzman sistemler, yapay sinir ağları gibi teknolojiler sayılabilir. İnsan makine etkileşimi olarak yinelemeli işlem uygulamaları ve makine çözümünün ardından insan kabulü şeklinde yapılan uygulamalar sayılabilir. Yöneylem araştırmaları ise üç gruba ayrılabilir. Bunlar; ardışık, kümeleme ve meta sezgisel yöntemlerdir. Bu konuda ilk çalışmaları yapan John Holland doğal evrimden ve canlılardaki bu süreçten yararlanarak, makine öğrenmesi üzerine çalışmalarını yoğunlaştırmıştır. Holland'ın asıl amacı, belirli problemleri çözmek için algoritma tasarlamak değil; uyum olgusu üzerinde çalışmak ve doğal uyumun bilgisayar sistemlerinde kullanılabilmesini sağlamak olmuştur.

Emel ve Taşkın [21] yaptıkları çalışmada; bir arama ve optimizasyon yöntemi olan GA'yı ve uygulama alanlarını incelemişlerdir. Çalışmada ilk olarak GA kavramı ve temel teoremi hakkında bilgi verilmiş daha sonra basit GA'nın çalışma adımları ve parametre seçimi incelenmiş ve fonksiyon optimizasyonu için bir çözüm örneği verilmiştir. Kahraman ve Özdağlar [23] ile Özdağlar ve ark. [24], GA'larla kompleks içme suyu dağıtım sistemlerinin optimizasyonu konusunu incelemişlerdir. İki ayrı noktadan beslenen sistem için 4 farklı hidrolik konumu birlikte sağlayan çözüm geliştirilmiştir. Deliktaş ve ark. [25] tarafından yapılan çalışmada, betonarme kiriş tasarımı, kısıtlanmalı bir optimizasyon problemi olarak ele alınmış ve çözüm için evrimsel algoritma tabanlı GA tekniği kullanılmıştır. Tek açıklıklı dikdörtgen kesitli betonarme kirişlerin boyutları minimum maliyetli olacak şekilde optimize edilmiştir.

Sumer ve Turker [26] yaptıkları çalışmada, yüksek çözünürlüklü uydu görüntüleri ile GA tabanlı bina algılama yaklaşımı geliştirmişlerdir. Bu yaklaşım, geleneksel ile evrimsel tekniği birleştiren hibrit bir sistemden oluşmaktadır. GA ile elde edilen uygunluk değerleri, geleneksel sınıflandırma yöntemine göre daha yüksek olmuştur. Cimen [27] yaptığı çalışmada, insansız hava araçlarının hareket halindeki hedefleri ve düşman saldırı durumları için rota planlama problemini, parçacık sürü optimizasyonu ve GA kullanarak modellemişlerdir. Algoritmaların birbirlerine göre kıyaslanmaları için çoklu hedefler ve düşmanlar üzerinden senaryolar geliştirilmiştir. Bununla birlikte, eksik bilgi ve dinamik çevre etkisi dikkate alınarak gerekli hareket ve opsiyonlar düşünülmüştür. Çalışma sonucunda GA ve PSO modelleme karşılaştırırken, GA'nın karar vermede daha etkili olduğu görülmüştür. Ceylan ve Haldenbilen [28], AB ve Türkiye'de ulaşım sektöründeki sosyo-ekonomik göstergelere göre geleceğe yönelik ulaşım talebini belirlemek için GA tekniğini kullanmışlardır. Yolcu, yük ve taşıt-km parametreleri için doğrusal ve doğrusal olmayan modeller geliştirilmiş ve modeller arasından geleceğe yönelik senaryoları hazırlayarak kullanılmışlardır. Bu senaryolara göre; 2025 yılında mevcut karayolu ulaşımı, yıllık yatırım hızı da dikkate alınarak talebi karşılamayacağını belirlemişlerdir.

Genetik algoritmaların çizelgeleme problemi ile ilgili ilk çalışmayı Davis 1985 yılında yapmıştır [29]. 1987'de Liepins et al., belirli teslim tarihleri ve işlem süreleri olan işlerin çizelgelemesi problemini araştırdılar [30]. Bu problem en basit çizelgeleme problemi olarak adlandırılmaktadır. 1993'de Gupta et al., akış zamanını minimize etmek için tek makineli model ile ilgili çalışma yayınlamışlardır [31]. Lee et al. 1995'de gecikme ve sarkma cezalarını da modele ilave eden çalışmalar yapmışlardır [32, 33]. Bunların yanında; iş atölyesinin çizelgeleme problemini çözmek için Biegel and Davern'nin, 1990'da akış atölyesinin problemini çözmek için Badami and Parks'ın 1991'de, süreç planlama problemini çözmek için Vancza and Markus'un 1991'de yayınlanmış çalışmaları vardır [34]. Son yapılan çalışmalarda, ders çizelgeleme probleminin çözümünde Genetik Algoritma ve Great Deluge algoritmasına dayalı yeni bir melez algoritma kullanmıştır [35].

Wijaya and Manurung yaptıkları çalışmada, Genetik Algoritma ile Endonezya Üniversitesi Bilgisayar Bilimleri Fakültesi için gerçek kısıtlarla modellenmiş bir çizelgeleme problemini başarılı bir şekilde tüm kısıtları yerine getiren bir çözüm üretmişlerdir [36]. Jat and Yang yaptıkları çalışmada, Genetik Algoritma ile rehberli bir araştırma stratejisi ve bir yerel arama tekniği kullanarak üniversite ders çizelgeleme probleminin çözümüne ilişkin sonuçlar elde etmişlerdir [37]. Bağış, Erciyes

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

Üniversitesi Elektronik Bölümü ders programı optimize etmiştir. Önceden belirlenen nesnelerin belirli konumlara en uygun şekilde yerleştirilmesi, bir optimizasyon problemi olduğundan GA'nın kullanılabilirdiği bu çalışmada; 4 bilgi dosyasından yararlanılarak hoca, derslik, sınıf, gün sayısı ve hocaların kişisel tercihlerine göre program gerçekleştirilmiştir [38]. Özçelik doktora çalışmasında, tek yönlü dairesel malzeme aktarma sistemlerinin kullanıldığı üretim sistemlerinde karşılaşılan istasyon yerleşim problemi GA ile çözümlenmeye çalışılmıştır. Yükleme ve boşaltma istasyonu sayısının ve konumunun belirlenmesi problemi, dengeli ve dengesiz akış durumlarına göre ayrı ayrı incelenmiştir [39]. Paksoy yaptığı doktora çalışmasında, yöneticilerin belirttiği takvimler çerçevesinde faaliyetlerin belli bir sırada sıralanması problemi olan 'Etkin ve uygulanabilir kaynak kısıtlı proje çizelgeleme problemi' minimum proje süresine sahip çizelgeleme işlemi GA ile hazırlamıştır. Elde edilen proje bitirme sürelerinin tatmin edilebilir düzeyde olduğu gözlenmiştir [40]. Tunalioglu ve Öcalan yaptıkları çalışmada, GA'nın ulaştırma alanında karayolu güzergahlarının belirlenmesi problemine uygulanmasını ele almışlardır. GA'nın karayolu güzergah optimizasyonunda makul ve kabul edilebilir sonuçlar verdiğini belirlemişlerdir [41]. Aslantaş ve Kurban yaptıkları çalışmada, GA kullanarak dalgacık domeninde görüntü kaynaştırma tabanlı bir görünür damgalama yöntemi geliştirmişlerdir. Farklı barındırıcı resim ve damga üzerinde gerçekleştirilen simülasyonlarda önerilen bu yöntem ile hem sayısal hem de görsel olarak iyi sonuçlar verdiği görülmüştür [42]. Gültekin Toroslu ve Börklü tarafından yapılan çalışmada, parçaların minimum maliyette mümkün olabilecek tolerans değerlerinin tahmini için GA'lar kullanılmıştır. Bu çalışma ile, Bilgisayar Destekli Tasarım model tolerans verilerini, otomatik değerlendirecek bir yöntem ve imalat esnasında kullanılacak optimum toleransları GA ile tahmine dayalı bir yaklaşım geliştirme amaçlanmıştır. Geliştirilen yazılımın tasarımcılara, hatasız veya en az hata ile ve en ucuz maliyetli tolerans atama işleminde destek sağlayacağı belirtilmiştir [43]. Gülsün ve ark. tarafından yapılan çalışmada, üretim tesislerinin etkin ve verimli bir şekilde işletilebilmesinde önemli bir role sahip olan tesis yerleşim tasarımı problemlerinin çözüm getirmesi açısından başarılı bir yöntem olan GA'lardan faydalanılmıştır. Karesel Atama Problemleri (KAP) kütüphanesinden alınan literatür problemleriyle test işlemleri yapılmış ve her problem için bilinen en iyi çözüme %99'dan daha fazla bir oranda yaklaşılmıştır [44]. Özşahin ve Oral yılında yaptıkları çalışmada, iki boyutlu dörtgensel şekillerin, iki boyutlu dörtgensel ve çember şeklindeki düzlemlere yerleştirilmesi amacıyla maksimum alan kullanımı ile yerleşimin yapılması amacıyla GA kullanılmıştır. Yapılan çalışma sonucunda GA'nın, iki boyutlu yerleştirmede başarılı sonuçlar verdiğini görülmüştür [45]. Kai C. ve ark. yaptıkları çalışmada, güçlendirilebilir gelişim kavramı adı altında Boundary-based seri GA olarak tanımlanan ve sezgisel bir yöntem olan çoklu amaçlarla kullanımı için optimal çözümler önermişlerdir [46]. Bastı yaptığı çalışmada; hizmet veren tesisler ve talep noktaları arasındaki taşımalardan dolayı ortaya çıkan maliyetlerinin en aza indirilmesini amaçlayan yöntemler üzerinde durmuştur. Problem boyutları sınırlı olan kesin çözüm yöntemlerine göre daha avantajlı ve yaygın olduğunu belirlemiştir [47]. Aslantaş ve ark. tarafından yapılan çalışmada, yeni bir piksel tabanlı çoklu-odaklı görüntü birleştirme yöntemi sunulmuştur. Bu yöntemde kaynak görüntülerine ait noktasal dağılım fonksiyonlarının dağılım parametreleri, GA kullanılarak araştırılmıştır. Elde edilen noktasal dağılım fonksiyonları, yapay olarak bulanıklaştırılmış ve üretilen bu yapay görüntüler ve kaynak görüntüler kullanılarak görüntülerdeki net pikseller belirlenmiştir. Sayısal ve görsel olarak yapılan değerlendirme işlemlerinin klasik yöntemlere göre daha iyi sonuçlar verdiğini görülmüştür [48].

3. MATERYAL VE METOT

Bu çalışmada GA'nın operatörlerinden biri olan çaprazlama ile ilgili bazı yöntemler ele alınmıştır. Bu operatörde ebeveyn olarak seçilen iki bireyin temsil ettiği çözümlerin belirli parçaları karşılıklı olarak yer değiştirilerek yeni özellikte bireyler oluşturulur. GA'da çaprazlama noktası ya da noktaları rastgele olarak seçilir. GA'da geleneksel olarak kullanılan çaprazlama nokta sayısı birdir. Fakat daha fazla çaprazlama noktası kullanımını teklif eden deneysel çalışmalar vardır [44]. Çaprazlama yöntemleri açıklanırken şu tanımlar kullanılacaktır;

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

Terminoloji	
n	Popülasyon sayısı ya da popülasyondaki
i	Kromozom indisi. $i i \in \{0,1, \dots, n\}$
C_i	Popülasyondaki i -inci kromozom.
g	Bir kromozomdaki gen sayısı.
j	Gen indisi. $j j \in \{0,1, \dots, g\}$
G	Bir kromozomun j -inci geni.
Y_i	Çaprazlama sonucunda oluşan yavrular. $Y =$
R	Kromozomdaki çaprazlama aralığı. $R =$

Çaprazlama yöntemlerinde kullanılan matematiksel eşitliklerin daha kolay anlaşılması açısından aşağıdaki gibi bazı temel tanımların yapılmasında fayda vardır. Bir P popülasyonunda n adet C kromozomu olsun ve her bir kromozom popülasyonun bir alt kümesi olarak tanımlansın. Böylece **Eşitlik 1**'deki gibi bir matematiksel gösterimi yapılabilir.

$$P = \bigcup_{i=0}^n C_i = C_0 \cup C_1 \cup \dots \cup C_n \quad 1)$$


Her bir C kromozomu da g adet genden meydana gelmektedir. Buna göre her bir gen, kromozomun tek elemanlı bir alt kümesi olarak **Eşitlik 2**'deki gibi tanımlanabilir.

$$C_i = \bigcup_{j=0}^g G_j = G_0 \cup G_1 \cup \dots \cup G_n, \{\{G\}: G \in C_i\} \quad 2)$$

Böylece gen kümelerinin birleşimi bir kromozomu, tüm kromozom kümelerinin birleşimi de popülasyonu oluşturmuş olacaktır. Eşitlik tanımlarında kolaylık olması açısından popülasyondaki i -inci kromozomun j -inci genini tarif etmek için $C_i(j)$ biçiminde kullanmayı tercih ettik.

3.1. Tek Noktalı Çaprazlama

Tek noktalı çaprazlama operatörü, rasgele bir nokta (kesme) seçilir. Her iki kromozomda ilk genden başlanarak seçilen noktaya kadar olan genler alınır ve kromozomlar arasında karşılıklı olarak yer değiştirilir. **Şekil 2**'de tek noktalı çaprazlama örneği gösterilmektedir. Burada çaprazlama için referans noktası ($r = 4$) olarak belirlenmiştir. Ebeveyn X'ten alınan $s_x = \{1,4,5,3\}$ gen sekansları Yavru B'ye ve Ebeveyn Y'den alınan $s_y = \{2,0,1,9\}$ gen sekansları Yavru A'ya aynı sıra düzeninde ve çapraz olarak transfer edilmiştir. Her bir yavru için geriye kalan genler sırasıyla Ebeveyn X'ten Yavru A'ya ve Ebeveyn Y'den Yavru B'ye transfer edilir.



Şekil 2: Tek noktalı çaprazlama örneği.

Eşitlik 3'te C_x ve C_y kromozomlarından çaprazlanarak elde edilen Y_A ve Y_B yavruları gösterilmektedir.


GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

$$Y_A = \bigcup_{j=0}^g \begin{cases} C_x(j), & (j \geq r) \\ C_y(j), & \text{değilse} \end{cases}, Y_B = \bigcup_{j=0}^g \begin{cases} C_y(j), & (j \geq r) \\ C_x(j), & \text{değilse} \end{cases}, x, y | x, y \in \{0,1, \dots, n\} \wedge x \neq y \quad (3)$$

Burada G kromozomdaki gen sayısını, j gen indisini, r çaprazlama referans noktasını, n popülasyon sayısını, C_x popülasyondaki x -inci kromozomu, $C_x(j)$ ise x -inci kromozomun j -inci genini temsil etmektedir.

3.2. İki Noktalı Çaprazlama

Bazı durumlarda tek noktalı çaprazlama yöntemi yetersiz kalabilir ya da büyük parçalı blokların bozulması performansı düşürebilir. Bu sebeple iki noktalı çaprazlama yöntemi tercih edilebilir. Bu çaprazlama operatöründe, rasgele belirlenmiş iki adet nokta seçilir ve bu noktalar arasında kalan genler çaprazlanacak kromozomlar arasında yer değiştirilir. **Şekil 3**'te bu çaprazlama yöntemi için bir örnek verilmiştir. Burada Ebeveyn X'ten alınan $s_x = \{5,3,0,2\}$ gen sekansları Yavru B'ye ve Ebeveyn Y'den alınan $s_y = \{1,9,7,3\}$ gen sekansları Yavru A'ya aynı sıra düzeninde ve çapraz olarak transfer edilmiştir. Her bir yavru için geriye kalan genler sırasıyla Ebeveyn X'ten Yavru A'ya ve Ebeveyn Y'den Yavru B'ye transfer edilir. Dikkat edilirse, çaprazlama noktaları dışında kalan genler transfer edilirken ebeveynlerdeki aynı sıra ve düzende korunmuştur.



Şekil 3: İki Noktalı çaprazlama örneği.

Eşitlik 4'te C_x ve C_y kromozomlarından çaprazlanarak elde edilen Y_A ve Y_B yavruları gösterilmektedir.


$$Y_A = \bigcup_{j=0}^g \begin{cases} C_y(j), & j \geq r_{min} \wedge j < r_{max} \\ C_x(j), & \text{değilse} \end{cases}, Y_B = \bigcup_{j=0}^g \begin{cases} C_x(j), & j \geq r_{min} \wedge j < r_{max} \\ C_y(j), & \text{değilse} \end{cases} \quad (4)$$

Burada r_{min} ve r_{max} çaprazlama için seçilen iki noktayı (aralığı) temsil etmektedir.

3.3. Tekdüze (Uniform) Çaprazlama

Bir diğer çaprazlama operatöründe, Syswerda tarafından tanımlanan uniform çaprazlamadır. Bu yöntemde, kromozom gen uzunluğunda (g) ve rasgele olarak üretilmiş bir bit dizisi (*kalıp*) belirlenir. Bu dizi üzerinde "0" bit değerine sahip alanlar çaprazlama için gerekli olan geni X ebeveyninden, "1" bit değerine sahip alanlar ise Y ebeveyninden alınarak çaprazlama yapılır. Diğer yavru kromozom için bu işlemin tersi geçerlidir [49]. **Şekil 4**'te tekdüze çaprazlama yöntemi için bir örnek verilmiştir.

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ



Şekil 4: Tekdüze çaprazlama örneği.

Burada Ebeveyn X'ten alınan $s_x = \{4,0,6,7,9,8\}$ gen sekansları Yavru B'ye ve Ebeveyn Y'den alınan $s_y = \{0,7,8,5,6,4\}$ gen sekansları Yavru A'ya aynı sıra düzeninde ve çapraz olarak transfer edilmiştir. Her bir yavru için geriye kalan genler sırasıyla Ebeveyn X'ten Yavru A'ya ve Ebeveyn Y'den Yavru B'ye transfer edilir. **Eşitlik 5**'te C_x ve C_y kromozomlarından çaprazlanarak elde edilen Y_A ve Y_B yavruarı gösterilmektedir.


$$Y_A = \bigcup_{j=0}^g \begin{cases} C_y(j), & K[j] = 1 \\ C_x(j), & \text{değilse} \end{cases}, \quad Y_B = \bigcup_{j=0}^G \begin{cases} C_x(j), & K[j] = 1 \\ C_y(j), & \text{değilse} \end{cases} \quad (5)$$

Burada K uniform çaprazlama dizisini (kalıbını) ve $K[i]$ ise bu dizideki 0 ve 1 değerlerini temsil etmektedir.

Bazı optimizasyon problemlerin çözümünde yukarıda bahsedilen çaprazlama operatörleri faydalı olmayabilir. Bu tip problemlerde parametre değerlerinin yanı sıra kullanılan niteliklerin konumu ve düzeni önemlidir. Çizelgeleme Problemi ve Gezgin Satıcı Problemi bu tipteki problemlerdir. Standart çaprazlama operatörleri ile başarı sağlanmamasına rağmen yeniden dizilim sağlayan (*re-ordering*) operatörlerin bazı formlarında kombinasyonel optimizasyon problemlerine çözüm sağlanabilmektedir. Yeniden dizilim sağlayan operatörler gen dizilerinin farklı şekilde yerleşimlerine ve değerlendirilmesine imkân sağlar [38].

3.4. Kısmen Uyumlu Çaprazlama (PMX)


Goldberg ve Lingle tarafından 1985 yılında geliştirilen bu yöntem gezgin satıcı ve araç rotalama problemlerinde yaygın olarak kullanılmaktadır. Bu tip problemlerde dizileri oluşturan genlerin aynı dizi içinde tekrar etmemesi gerekir. PMX, tekrarı engelleyen bir yapıya sahiptir. Ayrıca bu yöntemde seçilen bir alt dizinin korunması sağlanarak yavru diziyeye aynen aktarılmaktadır [50]. **Şekil 5**'te kısmen uyumlu çaprazlama yöntemi için bir örnek gösterilmektedir. Bu yöntemin çalışma prensibi şu şekildedir; ilk aşamada **Şekil 5(a)**'da gösterildiği gibi, iki noktalı çaprazlama yönteminde olduğu gibi C_x ve C_y kromozomları için rastsal olarak ortak bir aralık ($R = \{r_{min}, \dots, r_{max}\}$) seçilir. Daha sonra, seçili olan aralıktaki genler **Şekil 5(b)**'de gösterildiği gibi, kromozomlar arasında karşılıklı olarak yer değiştirilmiş biçimde, sırasıyla Y_A ve Y_B yavruarına aynı konumda olacak şekilde transfer edilir.



Şekil 5: Kısmen uyumlu çaprazlama; (a) örnek kromozomlar, (b) durum I.

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ


Bir sonraki aşamada ise **Şekil 6(a)**'da gösterildiği gibi her bir yavru için tekrarlı olmayan genler transfer edilir. Bu işlem C_x kromozomundan Y_A yavrusuna ve C_y kromozomundan Y_B yavrusuna aynı konumda olacak şekilde gen aktarımı yapılır. Tüm bu işlemlerin ardından sırayla tüm yavru için eksik gen bilgileri kopyalanır. Kopyalama işlemi; Y_A yavrusundaki eksik genler C_y kromozomunda iki numaralı işlem adımında transfer edilmiş olan gen aralığından temin edilir. **Şekil 6(b)**'de kısmen uyumlu çaprazlama sonucunda elde edilen yavru gösterilmektedir.



Şekil 6: Kısmen uyumlu çaprazlama; (a) durum II, (b) durum III.

3.5. Sıralı Çaprazlama (OX)

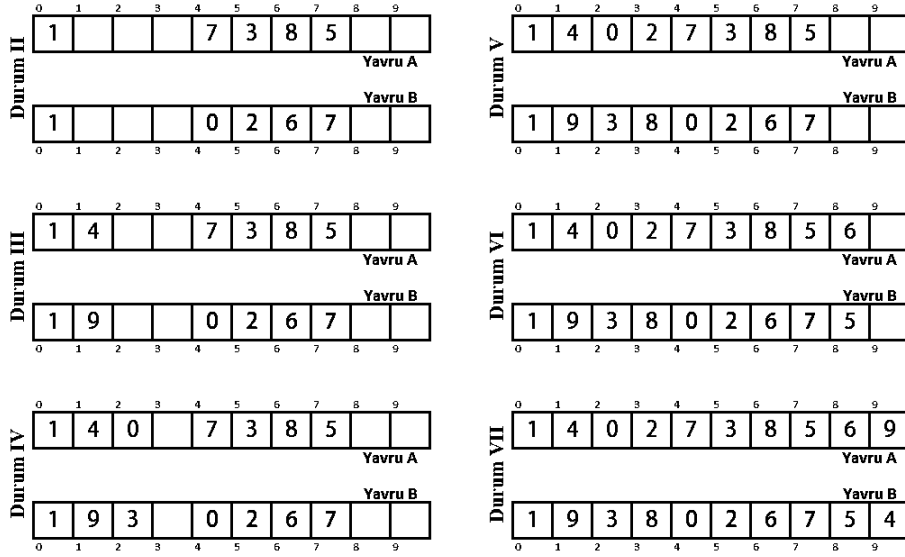
Bu yöntem, Davis, Goldberg ve Lingle tarafından geliştirilmiştir. Bu yöntemde, popülasyondan rastsal olarak seçilen kromozomlar üzerinde yine rastsal olarak iki ayrı kesim noktası (R) belirlenir. Bu kesim noktaları arasındaki kromozom sayısının her iki kromozomda da aynı olmasına dikkat edilir. Kesim noktaları arasındaki kromozomlar karşılıklı olarak yer değiştirilir. Kesim bölgesi dışında yer alan genler içerisinde tekrarlı genler oluşursa bunlar yerine sıra ile soldan sağa doğru kromozomda bulunmayan genler yazılır. OX yönteminin işleyişi aşağıda A ve B şeklinde kodlanmış olan iki kromozom üzerinde gösterilmektedir [50]. **Şekil 7**'de sıralı çaprazlama yöntemi için bir örnek gösterilmektedir. Bu yöntemin çalışma prensibi şu şekildedir; ilk aşamada **Şekil 7(a)**'da gösterildiği gibi, kısmen uyumlu çaprazlama yönteminde olduğu gibi C_x ve C_y kromozomları için rastsal olarak ortak bir aralık ($R = \{r_{min}, \dots, r_{max}\}$) seçilir. Daha sonra, seçili olan aralıktaki genler **Şekil 7(b)**'de gösterildiği gibi, kromozomlar arasında karşılıklı olarak yer değiştirilmiş biçimde, sırasıyla Y_A ve Y_B yavrularına aynı konumda olacak şekilde transfer edilir.



Şekil 7: Sıralı çaprazlama örneği.


Bir sonraki aşamada ise her bir yavru için tekrarlı olmayan genler transfer edilir. Bu işlem yapılırken öncelik sırası ebeveyn kromozomdaki gen indisine bakılır. Buna göre C_x kromozomun ilk indisinde bulunan gen Y_A yavrusuna transfer edilirken Y_A 'da bu genin olup olmadığı kontrol edilir. Eğer yoksa doğrudan gen transferi yapılır. Aksi durumda C_x kromozomun ikinci indisine geçilir ve tekrar Y_A 'da bu genin olup olmadığı kontrol edilerek, tüm genler eksiksiz bir şekilde tamamlanmaya kadar işlemler sürdürülür. Bu işlemler Y_B yavrusu içinde aynen geçerlidir. Farklı olan tarafı, C_x kromozomu yerine C_y kromozomundan gen transferinin yapılmasıdır. **Şekil 8**'de sıralı çaprazlamanın tüm aşamaları detaylı olarak gösterilmektedir.

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ



Şekil 8: Sıralı çaprazlama işleminin aşamaları.


Tüm bu işlemlerin ardından Şekil 9'da gösterildiği şekilde *A* ve *B* yavruları elde edilir.



Şekil 9: Sıralı çaprazlama ile oluşturulan yavrular.

3.6. Sıraya Dayalı Çaprazlama (OX2)


Bu yöntem ilk olarak Davis tarafından önerilmiştir [51]. OX2 yöntemi kullanıldığında bir ebeveynden seçilen konumlardaki gen dizisi diğer ebeveyndeki aynı değerli genlerin üzerine konulur. Bunun için OX yönteminde olduğu gibi rastgele olarak belirlenen bir kalıp dizisinin (*R*) belirlenmesi gerekmektedir. Şekil 10'da gösterilen kalıp dizisi $R = \{0,1,0,0,1,0,1,1,0,1\}$ olarak belirlenmiştir. Bu kalıp üzerindeki değeri 1 olan genler çaprazlama yapılacak bitlerin indisini temsil etmektedir.



Şekil 10: Sıraya dayalı çaprazlama örneği.

Buna göre, Ebeveyn Y (C_y)'den $s_y = \{0,7,8,5,4\}$ sekansları çaprazlanacak genler olarak seçilmiştir. Ebeveyn Y'de belirlenen bu genlerin diziliş sırasına göre Ebeveyn X'deki aynı değerlikli genler Şekil 11(a)'da gösterildiği şekilde düzenlenir. Aynı kalıp dizisine göre bu sefer Ebeveyn X (C_x)'den $s_x = \{4,0,6,7,8\}$ sekanslarının diziliş sırasına göre Ebeveyn Y'deki aynı değerlikli genler düzenlenir. Daha sonra eksik olan genler, C_x kromozomundan Y_A yavrusuna ve C_y kromozomundan Y_B yavrusuna aynı konumda olacak şekilde gen aktarımı yapılır. Böylece Şekil 11(b)'de gösterildiği gibi yavrular elde edilmiş olur.


GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ



Şekil 11: Sıraya dayalı çaprazlama işleminin aşamaları.


3.7. Dairesel Çaprazlama (CX)

Oliver, Smith ve Holland tarafından 1987 yılında geliştirilmiş bir yöntemdir. Bu yöntemde ilk olarak C_x kromozomundan sıfıncı indise sahip gen seçilir ve bu gene karşılık gelen (*aynı indis*) C_y kromozomundaki gen belirlenir. Daha sonra C_y kromozomundaki gen ile aynı değere sahip olan C_x kromozomundaki gen bulunur ve bu işlem en başta seçilen gen (C_x kromozomundan sıfıncı indise sahip gen) ile aynı değere sahip C_y kromozomundaki gen bulununcaya kadar devam ettirilir [6]. Şekil 12'de bu durumu gösteren bir dairesel çaprazlama örneği gösterilmektedir.



Şekil 12: Dairesel çaprazlama örneği.


Şekil 13(a)'da yukarıda bahsedilen süreç tamamlandıktan sonraki en son durumu göstermektedir. Daha sonra eksik olan genler, C_x kromozomundan Y_A yavrusuna ve C_y kromozomundan Y_B yavrusuna aynı konumda olacak şekilde gen aktarımı yapılır. Böylece Şekil 13(b)'de gösterildiği gibi yavrular elde edilmiş olur.



Şekil 13: Dairesel çaprazlama aşamaları.

3.8. Konuma Dayalı Çaprazlama (POS)

Syswerda tarafından 1991 yılında önerilmiştir. Konuma dayalı çaprazlamada da OX ve OX2 yönteminde olduğu gibi rastgele olarak belirlenen bir kalıp dizisinin (R) belirlenmesi gerekmektedir. Şekil 14'te gösterilen kalıp dizisi $R = \{0,1,0,0,1,0,1,1,0,1\}$ olarak belirlenmiştir. Bu kalıp üzerindeki değeri 1 olan genler çaprazlama yapılacak bitlerin indisini temsil etmektedir.




Şekil 14: Konuma dayalı çaprazlama örneği.

İlk işlem olarak, Ebeveyn X (C_x)'den seçilen $s_x = \{4,0,6,7,8\}$ sekansları Y_A yavrusuna ve aynı konumda olacak şekilde gen kopyalaması yapılır. Aynı şekilde Ebeveyn Y (C_y)'den $s_y = \{0,7,8,5,4\}$ sekansları da Y_B yavrusuna benzer şekilde kopyalanır. Bu durum Şekil 15(a)'da gösterilmektedir.

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ


Daha sonra eksik olan genler, C_x kromozomundan Y_B yavrusuna ve C_y kromozomundan Y_A yavrusuna soldan sağa doğru gen aktarımı yapılır. Böylece **Şekil 15(b)**'de gösterildiği gibi yavrular elde edilmiş olur.



Şekil 15: Konuma dayalı çaprazlama aşamaları.


3.9. Sezgisel Çaprazlama (*Heuristic Crossover*)

Grefenstette 1987'de kenar bilgileri üzerinde duran sezgisel çaprazlama operatörleri sınıfını geliştirmiştir. Bu yöntemin çalışma prensibi şu şekildedir; ilk aşamada **Şekil 16**'da gösterildiği gibi, C_x kromozomu için rastsal olarak bir aralık ($R = \{r_{min}, \dots, r_{max}\}$) seçilir. Daha sonra, seçilen gen değerlerinin farklı bir permütasyonu C_y kromozomunda aranır.



Şekil 16: Sezgisel çaprazlama örneği.


Şekil 17(a)'de C_x kromozomunda seçilen gen sekansları ve C_y kromozomunda bulunan farklı bir permütasyonunun yer değiştirmesi gösterilmektedir. Daha sonra **Şekil 17(b)**'de gösterildiği gibi eksik olan genler, C_x kromozomundan Y_A yavrusuna ve C_y kromozomundan Y_B yavrusuna aynı sırada gen transferi yapılarak çaprazlama süreci tamamlanmış olur.



Şekil 17: Sezgisel çaprazlamanın aşamaları.

3.10. Maksimal Koruyucu Çaprazlama (*Maximal Preservative Crossover-MPX*)

MPX operatörü ilk olarak Mühlenbein ve arkadaşları (1988) tarafından tanıtılmıştır. Bu yöntemde de **Şekil 18**'de gösterildiği gibi, C_x kromozomu için rastsal olarak bir aralık ($R = \{r_{min}, \dots, r_{max}\}$) seçilir.




Şekil 18: Maksimal koruyucu çaprazlama örneği.

Daha sonra, C_x kromozomu üzerinde seçilen gen sekansları C_y kromozomundan bulunarak silinir ve **Şekil 19(a)**'da gösterildiği biçimde geride kalan genler Y_A yavrusuna kopyalanır. Aynı işlem

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

ebeveynler yer değiştirilerek tekrarlanır ve bu seferde Y_B yavrusuna kopyalanır. Daha sonra **Şekil 19(b)**'de gösterildiği gibi C_x kromozomunda ilk etapta seçilmiş olan gen sekansları Y_A yavrusunun sıfırıncı gen indisinden başlamak üzere düzenlenir ve **Şekil 19(a)**'da gösterilen kalan genlerde soldan sağa doğru eklenir. Bu işlemin benzeri Y_B için de yapılarak çaprazlama süreci tamamlanmış olur.



Şekil 19: Maksimal koruyucu çaprazlama aşamaları.

4. SONUÇLAR

Genetik algoritmaların başlıca yeniliği çaprazlama adında yeniden oluşum operatörünü kullanmasıdır. Genetik algoritmalar, doğada gözlemlenen evrimsel sürece benzer bir şekilde çalışan arama ve eniyileme yöntemleridir. Genetik algoritma araştırmacıların karşılaştıkları problemleri çözmek için kullandığı ve bu doğrultuda en çok ilgilendiği konulardan birisi olarak bilinir. Problemlerin karmaşıklığı ve uygulamaların farklılığı nedeniyle genetik algoritmada kullanılan yöntemler sürekli olarak geliştirilmeye devam etmektedir. Geliştirilmeye devam eden çaprazlama yöntemi de genetik algoritmanın en önemli parçası olarak düşünülebilir. Çaprazlama ebeveynlerin bazı genlerini yeni bireyler üzerine aktarmaları veya diğer bir deyişle kopyalamaları işlemidir. Çaprazlama sonucunda yeni bireyler meydana gelmektedir. Popülasyonun neslinin devamı için bir sonraki jenerasyondaki başarılı bireyler arasından birey seçme işlemi gerçekleştirilir. Başarılı bireyler ebeveyn olarak kabul edilmek sureti ile aralarında üreme meydana getirilir. Yapılan bu çalışmada genetik algoritmada çaprazlama sonucu meydana getirilen bu bireylerin hangi yöntemler ile meydana gelebilecekleri süreçler ele alınmıştır. Ayrıca farklı 10 teknik ile açıklanan bu yöntemlerin matematiksel formülleri ve görselleri ile açıklanmıştır.

5. KAYNAKÇA

- [1]. Li, Y., Yang, Y., Zhou, L. and Zhu, R., 2009, Observations On Using Problem-Specific Genetic Algorithm For Multiprocessor Real-Time Task Scheduling, International Journal of Innovative Computing, Information and Control, 5(9), 1349-4198.
- [2]. Marwala, T. and Chakraverty, S., 2006, Fault classification in structures with incomplete measured data using autoassociative neural networks and genetic algorithm, Curr Sci India, 90, 542-548.
- [3]. Durukan, D., 2013, Doğrusal ve doğrusal olmayan kafes sistemlerin genetik algoritma ile optimum tasarımı, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
- [4]. Kuruca, E., 2009, Gezgin satıcı problemi tabanlı bir sistemin dinamik bulanık genetik algoritmalar ile optimizasyonu, Yüksek lisans tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 5-25.
- [5]. Çivril, H., "Hemşire Çizelgeleme problemlerinin genetik algoritma ile çözümü", Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta, 1-78 (2009).
- [6]. Goldberg, D. E., "Genetic algorithms in search optimization and machine learning", Addison Wesley Publishing Company, U.S.A., 1-10 (1989).
- [7]. Ü. B. Gürel, 2012, Sınav Çizelgeleme Probleminin Optimizasyonu, Maltepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
- [8]. E. Önder, 2011, Araç Rotalama Problemlerinin Parçacık Sürü ve Genetik Algoritma ile Optimizasyonu İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi.
- [9]. Michalewicz, Z., "Genetic Algorithms + Data Structures = Evolution Programs", Springer Verlag, USA, 1-10 (1996).
- [10]. Biroğul, S., "Genetik algoritma yaklaşımıyla atölye çizelgeleme", Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 28-47 (2005).
- [11]. Akbulut, D., "Evrimsel tasarım yöntemi ve yaratıcılığın süreç içerisindeki yeri", Gazi

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

- Üniversitesi Güzel Sanatlar Fakültesi Sanat ve Tasarım Dergisi, 2: 21-33 (2008).
- [12]. Biroğul, S. ve Güvenç, U., “Genetik algoritma ile çözümü gerçekleştirilen atölye çizelgeleme probleminde ürün sayısının etkisi”, Akademik Bilişim 2007, Kütahya, 1-10 (2007).
- [13]. Sivanandam, S.N., Deepa, S.N., 2008, Introduction to Genetic Algorithm, Berlin: Springer-Verlag.
- [14]. Haupt, R.L., Haupt, S.E., 2004, Practical genetic algorithms, Second Edition, New Jersey: Wiley-Interscience.
- [15]. Öztürk, M., 2008, Çok aşamalı tedarik zinciri optimizasyonu probleminin yayılan ağaç tabanlı genetik algoritma ile çözümü, Yüksek lisans tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, 52-70.
- [16]. Coloni, A., Dorigo, M. and Maniezzo, V., “Genetic algorithms: a new approach to the time-table problem”, Published in Lecture Notes Computer Science, Springer Verlag, 82: 235-239 (1992).
- [17]. Goldberg, D.E., 1989, Genetic algorithms in search optimization and machine learning, Addison Wesley Publishing Company, USA.
- [18]. Wang, C.-H. ve Lu, J.-Z., 2009, A hybrid genetic algorithm that optimizes capacitated vehicle routing problems, Expert Systems with Application, 36, 2921–2936.
- [19]. Tunalıoğlu, N., Öcalan, T., 2007, Üç Boyutlu Karayolu Güzergâh Optimizasyonunda Karar Destek Sistemi Olarak Genetik Algoritmaların Kullanımı, TMMOB Harita ve Kadastro Mühendisleri Odası 11. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.
- [20]. Topuz, V., “Bulanık genetik proses kontrolü”, Doktora Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 13-38 (2002).
- [21]. Emel, G.G. ve Taşkin, Ç., 2002, Genetik Algoritmalar ve Uygulama Alanları, Uludağ Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi, 21 (1), 129-152.
- [22]. Taç, K. C., “Genetik algoritma kullanılarak haftalık ders programı zaman çizelgeleme yazılımının geliştirilmesi”, Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 1-78 (2006).
- [23]. Kahraman, M.A. ve Özdağlar, D., 2004, Su Dağıtım Sistemlerinin Genetik Algoritma ile Optimizasyonu, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 6(3), 1-18.
- [24]. Özdağlar, D., Benzedem, E. ve Kahraman, M.A., 2006, Kompleks Su Dağıtım Şebekelerinin Genetik Algoritma ile Optimizasyonu, İMO Teknik Dergi, 3851-3867.
- [25]. Deliktaş, B., Türker, H.T., Coşkun, H., Bikçe, M. ve Özdemir, E., 2005, Genetik Algoritma Parametrelerinin Betonarme Kiriş Tasarımı Üzerine Etkisi, Deprem Sempozyumu, Kocaeli, 1524-1531.
- [26]. Sumer, E. and Turker, M., 2013, An Adaptive Fuzzy-Genetic Algorithm Approach for Building Detection Using High-Resolution Satellite Images, Computers, Environment and Urban Systems, 39, 48–62.
- [27]. Cimen, E.B., 2014, Air Combat with Particle Swarm Optimization and Genetic Algorithm, Journal of Aeronautics and Space Technologies, 7 (1), 25-35.
- [28]. Ceylan, H., Haldenbilen, S., 2005, Genetik Algoritma ile Avrupa Birliği Üyeliği Sürecinde Türkiye’de Beklenen Ulaşım Talebi ve Yönetimi Üzerine Bir Yaklaşım, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü Dergisi, 9 (1), 153-159.
- [29]. Davis, L., “Job shop scheduling with genetic algorithms”, Proceedings of the International Conference on Genetic Algorithms and Their Applications, Carnegie Mellon University, Pittsburgh, PA, 136-140 (1985).
- [30]. Liepins, G. E., Hilliards, M. R., Palmer, M. and Morrow, M., “GreedyGenetics: Genetic algorithms and their applications”, Proceedings of the Second International Conference on Genetic Algorithms, Cambridge, MA, 1-10 (1987).
- [31]. Gupta, M. C., Gupta, Y. P and Kumar, A., “Minimizing flow time variance in a single machine system using genetic algorithms”, European Journal of Operations Research, 70: 289-303 (1993).
- [32]. Lee, C. Y. and Choi, J. Y., “A genetic algorithm for job sequencing problems with distinct due dates and general early-tardypenalties”, Computers and Operations Research, 22: 857-869 (1995).

GENETİK ALGORİTMADA ÇAPRAZLAMA YÖNTEMLERİ

- [33]. Wadhwa S. and Chopra A., "A genetic algorithm application: dynamic re-configuration in agile manufacturing systems", *Studies in Informatics and Control*, 9: 1-9 (2000).
- [34]. Yeniay, Ö., "An overview of genetic algorithms", *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi*, 2(1): 37-49 (2001).
- [35]. Al-Milli, N. R., "Hybrid genetic algorithms with great deluge for course timetabling", *IJCSNS International Journal of Computer Science and Network Security*, 10(4): 283-288 (2010).
- [36]. Wijaya, T. and Manurung, R., "Solving university timetabling as a constraint satisfaction problem with genetic algorithm", In *Proceedings of the International Conference on Advanced Computer Science and Information Systems (ICACSIS)*, Depok, 1-10 (2009).
- [37]. Jat, S. N. and Yang, S., "A guided search genetic algorithm for the university course timetabling problem", *Multidisciplinary International Conference on Scheduling: Theory and Applications (MISTA)*, Ireland, 180-191 (2009).
- [38]. Bağış, A., 1996, *Genetik Algoritma Kullanılarak Ders Programının Optimum Şekilde Düzenlenmesi*, Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri, 76 sayfa.
- [39]. Özçelik, F., 2007, *Genelleştirilmiş Tek Yönlü Dairesel Yerleşim Problemine Genetik Algoritma Tabanlı Bir Çözüm Yaklaşımı*, Doktora Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir, 123 sayfa.
- [40]. Paksoy, S., 2007, *Genetik Algoritma ile Proje Çizelgeleme*, Doktora Tezi, Çukurova Üniversitesi Sosyal Bilimler Enstitüsü, Adana.
- [41]. Tunalıoğlu, N., Öcalan, T., 2007, *Üç Boyutlu Karayolu Güzergâh Optimizasyonunda Karar Destek Sistemi Olarak Genetik Algoritmaların Kullanımı*, TMMOB Harita ve Kadastro Mühendisleri Odası 11. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.
- [42]. Aslantaş, V. ve Kurban, R., 2008, *Genetik Algoritma Kullanarak Görüntü Kaynaştırma Tabanlı Görünür Damgalama*, 3. Uluslararası Katılımlı Bilgi Güvenliği ve Kriptoloji Konferansı, Ankara, 178-182.
- [43]. Gültekin Toroslu, A. ve Börklü, H.R., 2009, *Gerçekleştirilebilir Toleransların Genetik Algoritma Metodu ile Belirlenmesi*, *TUBAV Bilim Dergisi*, 2:(2), 185-198.
- [44]. Gülsün, B., Tuzkaya, G. ve Duman, C., 2009, *Genetik Algoritmalar ile Tesis Yerleşimi Tasarımı ve Bir Uygulama*, *Doğuş Üniversitesi Dergisi*, 10 (1), 73-87.
- [45]. Özşahin, M., Oral, M., 2010, *Genetik Algoritma ile İki Boyutlu Şekil Yerleştirme*, *Bilimde Modern Yöntemler Sempozyumu*, Diyarbakır, 415-432.
- [46]. Kai, C., Bo, H., Shaowen, W. and Hui, L., 2011, *Sustainable land use optimization using Boundary-based Fast Genetic Algorithm*, *Computers, Environment and Urban Systems*, 36, 257-269.
- [47]. Bastı, M., 2012, *P-medyan Tesis Yeri Seçim Problemi ve Çözüm Yaklaşımları*, *Online Academic Journal of Information Technology*, 3 (7), 47-75.
- [48]. Aslantaş, V., Toprak, A. N., Kurban, R., Bendeş, E., 2013, *Çoklu-Odaklı Görüntülerin Genetik Algoritma Kullanılarak Birleştirilmesi*, *Mühendislik ve Fen Bilimleri Dergisi*, 25-37.
- [49]. Syswerda, G., "Uniform crossover in genetic algorithms", In *Proceedings of the Third International Conference on Genetic Algorithms*, U.S.A., 2-9 (1989).
- [50]. Engin, O. ve Fırlalı, A., "Akış tipi çizelgeleme problemlerinin genetik algoritma yardımı ile çözümünde uygun çaprazlama operatörünün belirlenmesi", *Doğuş Üniversitesi Dergisi*, 6: 27-35 (2002).
- [51]. Cheng, R., Gen, M. and Tsujimura, Y., "A tutorial survey of job shop scheduling problems using genetic algorithms: Part 2. Hybrid genetic search strategies", *Computers and Industrial Engineering*, 37: 51-55 (1999).

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

Cenk Şahin^{1*}, Sakhi Mohammad Hamidy¹, Melek Işık¹

¹ Çukurova Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü, Sarıçam, Adana

cenksahin@cu.edu.tr

*Sorumlu Yazar

1. GİRİŞ

Günümüz rekabet piyasasında işletmeler hayatta kalabilmek için her yönden güncel teknoloji ve yöntemleri kullanmak zorundadır. Bu gereklilik özellikle piyasanın globalleşmesinden doğmuş ve müşterinin söz sahibi olmasında büyük rol almıştır. Bu ortamda rekabet eden işletmeler yaptıkları her hareketle müşteri, tedarikçi ve diğer rakipleri tarafından reaksiyon almaktadır. Bu durumun farkına varan işletmeler artık yaptıkları işlerde farklılaşmaya gitmekte ve başta müşterileri olmak üzere tedarikçi ve rakip firmalarında iyi bir intiba bırakmak zorundadır.

Piyasada artık stratejiler üretilen satılır anlayışından çıkmış onun yerine gerekli özellikleri taşıyan ve piyasada talep edilen ürünlerin kaliteli ve doğru bir şekilde arz edilmesine dönmüştür. Bu konuda özellikle farklı çalışmalarda bulunan birçok işletme genel ve yerel uygulamalara başvurmaktadırlar. Bu uygulamalar aynı zamanda kalitenin gelişimine katkıda bulunmaktadır ve uygulanabilir metodlar ortaya çıkarmaktadır.

Bahsedilen bu piyasa koşulları ve rekabette en önemli rekabet araçlarından birisi ve en prestij sağlayıcı kaliteli ürün veya hizmet sağlamaktır. Kalite kavramı geçmişi köklü olan ve gereklilikler dahilinde ortaya çıkan bu kavram daha sonra çok hızlı gelişim göstererek piyasaların vazgeçilmezi haline gelmiştir. Kalitenin gelişimi işletmelerde yeni birimler ortaya çıkarmış ve birçok maliyetin önüne geçilmesine sebep vererek işletmelerde tasarruf ve müşteri ile tedarikçide ise memnuniyet sağlamıştır.

Yapılan bu çalışmada üretim sektörü içerisinde faaliyet gösteren işletmelerin etkin kalite kontrolünü sağlayacak çözümler aranmış ve bu bağlamda öncelikle çalışmanın 1. bölümünde konuya kısa bir giriş yapılmıştır. Daha sonrasında sırasıyla 2. ve 3. bölümlerde kalite ve kalite kontrol kavramı detaylıca incelenmiştir. 4. Bölümde ise işletmelerin kalite kontrol süreci için görsel sunum aracı tasarımına ve Microsoft Access programı kullanılarak yapılan örnek bir veritabanı programı uygulamasına yer verilmiştir. Çok fazla makro ve sql kodlarının kullanıldığı programda amaç işletmelerde yer alan hata türlerini belirleyip görselleştirerek izlenebilirliğini sağlamak olmuştur. Bu konuda farklı raporlar hazırlanmış ve grafiklerin yardımıyla izlenebilirliği ve çeşitli açılardan kalite kontrolün yapılması sağlanmıştır. Çalışma sonucunda oluşturulan kalite kontrol süreci için görsel sunum aracı hakkındaki sonuçlar ve öngörülen öneriler 5. bölümde yer almıştır.

2. KALİTE KAVRAMI

İşletmelerin genellikle temel amaçları kar etmektir. Bu amaca ulaşmak için işletmelerin oluşumunda çeşitli yapılanmalara gidilir. Günümüzde her işletmenin yönetimini sağlamak için bir organizasyon yapısı bulunmaktadır. Bu yapılar genelde hiyerarşik yapıda olup görev paylaşımına dayanmaktadır. Bütün bu yapılanmanın tek amacı verilecek olan hizmet veya ürünün müşterinin istediği gibi olması ve memnuniyetin sağlanmasıdır. Bu amacı içinde barındıran kavram kalitedir. Başta üretim işletmelerinde kalite ön planda bulunan bir kavramdır. Kalitenin işletmeciler için maliyet olmadığı aslında kalitesizliğin doğuracağı ağır maliyetlerin olduğu günümüz işletmelerinde genel kabul görmüş bir kaide olduğu bilinmektedir. Hizmet sektöründe ise kalite daha hassas bir

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

derecededir. Üretim işletmelerinde kalitesizliğin telafisi nispeten olsa da hizmet sektöründe faaliyet gösteren işletmeler için kalitesizliğin maliyeti oldukça ağır ve geri dönüşü çok zor olan bir durumdur. Kalitenin bu denli öneme sahip olduğu bir ortamda öncelikle bu kavramın neler içerdiğini ve ne anlamlara geldiğini daha önceki çalışmalar ışığında görmek yararlı olacaktır.

2.1. Kalitenin Tanımı

Kalite kavramı günümüzde gittikçe artan bir sıklıkta kullanılmaktadır. Fakat akademik yayınlarda veya endüstride bu kavram için kavram birliği görülmemektedir. Genellikle çoğu kişi tarafından kaliteli mamulü ya “pahalılığına” ya da “sağlamlığına” bakarak tanımlanır. Bunun neticesinde kalite günlük yaşamımızda çoğu kez eksik, yanlış veya gerekenden daha dar bir kapsamda ifade edilmektedir. Kaliteyi kesin bir şekilde tanımlamadan önce kalitenin kesinlikle ne olmadığını belirtmesi gerekir (Güleş, 1990).

Kalite kavramı tek boyutlu bir kavram olmayıp gerek günlük yaşantımızda ve gerekse bilimsel platformlarda yapılan tartışmalarda üzerine muhtelif anlamlar yüklenmiş olarak karşımıza çıkmaktadır. Bir ürünün kaliteli olmasından söz eden bir kimse fiyatını ima ediyor olabileceği gibi dayanıklı olduğunu veya performansının son derece yüksek olduğunu da ima ediyor olabilir. Kalitesi ve fiyatı yüksek bir ürün, kalitesiyle bağdaşmayacak amaçlar için kullanılıyorsa, aynı işi kalitesi ve fiyatı daha düşük bir başka ürünle görmek mümkünse ilkinin yeterince kaliteli olduğunu söylemek doğru bir değerlendirme olmaz. Bir ürünün kalitesini geliştirmesinden söz ederken de benzeri çelişkiler ortaya çıkar. Çapı 50 mm olan bir mil ± 0.05 mm. toleransla bir işi görürken, tolerans limitlerini ± 0.005 mm.’ye indirmek ve bu iş için yatırım yapmak hiç de akıllıca bir iş değildir. Kalitesi ve fiyatı yüksek bir ürünün yerini, kalitesi ve fiyatı düşük bir başka ürün tutabiliyorsa ikincisi birinciye tercih edilecek, birincisi için “kaliteli bir üründür.” demeye devam edilmeyecektir. Bu çerçevede kaliteyi “amaca uygunluk derecesi” olarak tanımlamak yerinde olacaktır (Yüksel, 1992).

Kalitenin dar anlamda “standartlara uygunluk” şeklinde tanımladığımızı görüyoruz. Bu tanım, ürünün tasarım aşamasında belirlenen standartlara ve spesifikasyonlara uygun olmasını ve bu standart ve spesifikasyonlardan kabul edilebilen sınırlar (tolerans sınırları) içinde minimum sapma göstermesini içermektedir. Tanımdan da anlaşılabilir gibi, bu yaklaşım kaliteyi üretici açısından değerlendirmektedir. Kalite, “kalite tüketicinin tatminidir” veya “kalite kullanımına uygunluktur” şeklinde tanımlandığında ise, kavrama tüketici ya da müşteri açısından yaklaşmakta ve kalite, tüketicinin memnuniyet derecesi veya başka bir deyişle, tüketicinin ürüne ilişkin tutumunun ölçüsü olarak ele alınmaktadır. Benzer bir tanımlama “kalitenin, bir ürünün tasarımında, spesifikasyonlarında ve üretiminde mükemmellik” olduğu şeklindedir. Çağdaş anlamda kalite ise, bu ikinci bakış açısından ele alınarak üreticiden çok, ürünü kullanacak olan tüketiciyle ilgili bir kavram olarak değerlendirilmektedir. Dolayısıyla, bir ürünün kaliteli olup olmadığına, ihtiyaçlarının ve beklentilerinin karşılanıp karşılanmamasına göre tüketici karar verecektir. Bu bakımdan, kalitenin ürünün fonksiyonuna veya hizmet ettiği amaca göre bir anlam taşıyabileceğini ve bu noktadan hareketle “amaca uygunluk derecesi” şeklinde de tanımlanabileceğini söyleyebiliriz (Akbul, 2010).

Kalite kelimesinin Latince’deki “qualis” kelimesinde türemiş olup “qualites” olarak ifade edildiğini söylenmektedir. Dünya çapındaki kuruluş ve uzmanlar tarafından yapılmış olan kalite tanımları aşağıda verilmiştir (Kayaalp, 2007).

- Kalite kullanıma uygunluktur (J.M.Juran)
- Kalite bir ürünün gerekliliklere uygunluk derecesidir (P.Crosby)
- Kalite, ürünün sevkiyattan sonra toplumda neden olduğu minimal zarardır (G.Taguchi)
- Kalite, bir mal yada hizmetin belirli bir gerekliliği karşılayabilme yeteneklerini ortaya koyan karakteristiklerin tümüdür (ASQ)
- Kalite, bir mal yada hizmetin tüketicinin isteklerine uygunluk derecesidir (EQO)

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

2.2. Kalitenin Boyutları

Kalite çeşitli çalışmalarda farklı boyutlarda ele alınmıştır. Bu boyutlarda incelenmesinin temel nedenleri kalitenin çeşitli şekillerde tanımlanmasından kaynaklanmaktadır.

2.2.1. Performans

Performans, üründe bulunması gereken birinci derecede önemlilik arz eden özelliktir. Ürün ya da hizmetin kendisinden beklenen görevleri (fonksiyonları) ne derece yerine getirdiğinin bir ölçüsüdür. Ürünlerin ya da hizmetin beklenen ana fonksiyonları, temel işlevleri yerine getirip getirmeme kabiliyeti ve gösterdikleri başarı açısından değerlendirilmesidir. Bu özellik her ürün ve hizmette farklı etkinliğe sahiptir (Pekmezci, 2005; Kayaalp, 2007; Yıldırım, 2015).

2.2.2. Güvenilirlik

Güvenilirlik, ürünün ne kadar sıklıkla arızalandığı sorusunun cevabı ile ilişkilidir. Örneğin müşterilerin bir otomobil için yıllık bakım bekleyip planlarken daha sık bakım ihtiyacı ile karşılaşmaları güvensizlik yaratır. Ürünlerin beklenenden fazla servis görmesi müşteri şikâyetlerinin bir nedenidir. Güvenilirlik ölçülebilen bir değerdir (Yıldırım, 2015).

2.2.3. Uygunluk

Uygunluk, ürünün tasarımcının belirlediği toleranslara, gerekli yasal düzenlemeler ve standartlara uygunluğudur (Yıldırım, 2015).

2.2.4. Dayanıklılık

Mamulün bozulmadan kullanılma süresi dayanıklılık olarak tanımlanmaktadır. Satın alınan ürünün beklenen performansta ne kadar süre çalışabildiği sorusunun cevabı dayanıklılığın karşılığıdır (Kayaalp, 2007, Yıldırım, 2015).

2.2.5. Hizmet görürlük (servis kolaylığı)

Ürün/hizmet ile ilgili ortaya çıkan sorun ve şikâyetlerin kolay çözülebilirliği “Ürün ne kadar kolay tamir edilebilir?” sorusuna verilecek yanıt ile doğrudan ilişkilidir. Üründe bir hata oluştuysa bu hatanın tamir edilebilme süresi ve kolaylığı kalitesi ile orantılıdır (Yıldırım, 2015).

2.2.6. Estetik

Ürünün albenisi ve duylara seslenebilme yeteneği ürününü estetikliğini ifade etmektedir. (Kayaalp, 2007). Estetiklik, tüketicilerin beş duyusuna hitap eden ürün özellikleridir. Ürünün görsel özellikleri ürünün performansını direkt etkilemese de kalite algılamasının bir boyutudur. Bazı endüstrilerde fark yaratmak için bu boyutu tercih ederler. Örneğin meyve suyu üreticileri ürünlerin farklılıklarını genellikle ambalajlarındaki görsellikler ile ortay koyarlar (Yıldırım, 2015).

2.2.7. Özellikler

Özellik, ürünün fonksiyonel çeşitliliğidir. Potansiyel müşteriler ana fonksiyona ilave farklı ve kullanışlı fonksiyonları da olan ürünleri tercih ederler. Örneğin istatistiksel analizler de yerleştirilmiş bir test cihazı yazılımı sadece kontrol sağlayan bir yazılımdan çok daha fazla tercih edilecektir (Yıldırım, 2015).

2.2.8. İtibar

Ürünün/hizmetin geçmişte sergilediği performans o ürünün/hizmetin itibarıdır (Kayaalp, 2007).

2.2.9. Algılanan kalite

Potansiyel müşterilerin bir markayı tercih etmesinde ilgili markanın başka ürünler ile geçmişte oluşturduğu kalite izlenimi oldukça etkilidir. Algılanan kalite, müşteri sadakati ve tekrar eden alışveriş yakından ilişkilidir (Yıldırım, 2015).

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

2.2.10. Diğer unsurlar

Diğer unsurlar, ürünün çekiciliğini sağlayan ikincil karakteristiklerdir (Kayaalp, 2007).

3. KALİTE KONTROL KAVRAMI

Kalite kontrol kavramına bakıldığında öncelikli olarak rekabetin vazgeçilmeyen bir parçası olarak görünmektedir. İşletmeler özellikle kalitenin değil kalitesizliğin bedelini ödemek durumunda kalmaktadırlar. Bu kapsamda kaliteye bakılırken maliyetin düşürülmesi ve müşteri sürekliliği ile markalaşmaya giden yolda önemli bir adım olduğu bilinmelidir. Her yeni pazara açılırken işletmeler daha önceki izlenimleri üstünde taşımaktadırlar. Bu da kalitenin aynı zamanda işletmelerin prestijini de yansıtmaktadır.

3.1. Kalite Kontrolün Tanımı

M.Ö. 2150 yıllarına ait kayıtlarda insanların hata yapmak istemedikleri ve mükemmelle ulaşmak istemeleri farkedilmiştir. Ünlü Hamurabi kayıtlarında, yeterince sağlam inşaat yapmayan ve yaptığı inşaatın çöküp ölüme sebep olan bir inşaat ustasının başının uçurulduğundan bahsedilmektedir (Koçak, 2013).

Kontrol, herhangi bir faaliyetin hedeflenen amaçları gerçekleştirebilecek biçimde önceden saptanan kurallar çerçevesinde yürütülmesi sağlama fonksiyonu olarak tanımlanabilir. Kalite kontrol ise, kalite hedeflerini sağlamak amacıyla uygulanan teknikler ve faaliyetlerdir. Başka bir deyişle, ekonomik etkinliğin sağlanabilmesi amacıyla üretim süreci içinde çeşitli aşamalarda üretim sürecinin gözlenmesi ve yetersiz performansa yol açan nedenlerin ortadan kaldırılmasını amaçlayan işlemler ve uygulama teknikleridir (Akbul, 2010).

Gökkaya (2008)'e göre kalite kontrolü, tüketici isteklerini en ekonomik düzeyde karşılamak için işletmedeki çeşitli birimlerde kalitenin yaratılması, yaşatılması ve geliştirilmesi yolunda gösterilen çabaların birleştirildiği bir sistemdir (Gökkaya, 2008).

İşletmeler müşteri isteklerini karşılamayı, müşteri memnuniyetini temin etmeyi ve işletme verimliliğini artırabilmek için üretmiş oldukları ürünlerin kaliteli olmasını sağlayacak sistemi oluşturmayı amaçlarlar. İşletmelerin bu amacı gerçekleştirme çabaları, zaman içinde kalite kontrolü kavramının sürekli evrim geçirmesine neden olmuştur (Deste, 2008).

Genel anlamda kalite kontrol herhangi bir kalite karakteristiğinde spesifikasyonlara göre sapma olması durumunda, düzeltici aksiyonların uygulanmasını sağlayarak istenilen kalite seviyesini koruyan sistemdir. Jozsef ve Blaga (2014) kalite kontrolü, kalite gereksinimlerinin karşılanması için uygulanan operasyonel teknikler ve aktiviteler serisi olarak tanımlamışlardır. Özellikle seri imalat endüstrisinde yakalanamayan bir hatalı ürün, ürünlerin sahadan toplanması ve kitlesel hurda gibi üreticilerin kâbusu olan durumlar ile sonuçlanabilir. Bu durumun sebep olacağı kayıplar ise yeniden işleme alınma maliyeti, prestij kaybından dolayı pazar payında oluşacak küçülme ve lojistik maliyeti gibi kalemlerden oluşacaktır. Tüm bu kayıpların önüne geçmek için hatanın oluşumunun önlenmesi ve oluşan hatanın ise yakalanması istenir. Bu amaçla kalite kontrol planları oluşturulmaktadır (Yıldırım, 2015).

3.2. Kalite Kontrolün Tarihsel Gelişimi

Sanayide ilk kalite kontrol çalışmalarının nihai ürün üzerinde yapılan kusurlu kusursuz ayrımı ile başladığını görüyoruz. İmalat süreci sonunda elde edilen nihai ürünün önceden belirlenen standartlara uygun olup olmadığını tespit etmek için kullanılan muayene işlemiyle kusurlu ürünler ortaya çıkarılarak, bu ürünlerin müşteriye ulaşmasını engellemek ve böylelikle tüketiciyi kusurlu üründen korumak amaçlanmıştır. Ancak, kontrol işleminin üretim süreci tamamlandıktan sonra nihai ürün aşamasında yapılması, ürün kalitesinin sağlanması açısından oldukça yetersiz ve pahalı olup, üreticiye zarar vermektedir. Şöyle ki; her ürün imalat süreci boyunca bir takım üretim maliyetlerine sebep olur. Kusurlu ya da kalitesiz ürünün üretim işlemi tamamlandıktan sonra tespiti o ürün için katlanılan maliyeti zarara dönüştürülür (Akbul, 2010).

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

Kalite kontrolün başlangıcı endüstri devriminden sonra, 1920'li yıllara dayanmaktadır. 1920'li yıllarda test ve muayene yapmak için Bell Telefon Laboratuvarları tarafından kalite bölümleri kurulmuştur. 1924 yılında Bell Telefon Laboratuvarları'nda kontrol diyagramlarını ilk kez Walter A. Shewhar tarafından kullanılmaya başlanmıştır. 1932'de Londra Üniversitesinde ilk kez üretim ve kontrol diyagramlarında istatistiksel metotlar eğitimi verilmiştir. 1942 ile 1946 yılları arasında endüstride kalite kontrol eğitim kursları verilmiş ve Kuzey Amerika'da konu ile ilgili çalışan 35'ten fazla kurum kurulmuştur (Özkale, 2004).

3.3. Kalite Kontrolün Amaçları

Kalite kontrolün esas amacı; tüketici isteklerinin mümkün olduğunca en ekonomik düzeyde karşılayan ürün/hizmet sunmaktır. Kalite kontrolün ana amacın yanı sıra; verimliliği artırmak, üretim giderlerini düşürmek, güvenilirliği artırmak, müşteriye memnun etmek, hatalı ürün sayısını düşürmek, rekabet üstünlüğü kazanmak, termin sürelerine sadık kalmak, üretim kayıpları ve gecikmeleri azaltmak, gibi birkaç alt amaç sıralanabilir (Gökkaya, 2008).

İşletmeler müşterinin şikayetçi olmayacağı ve tekrar talep edeceği bir mal veya hizmeti üretmek isterler. Bu yüksek kalite düzeyine en ekonomik şekilde ulaşmak isterler. Bunun için işletmedeki tüm bölümlere sorumluluk yüklenmesi gerekmektedir. Tüketici isteklerini ve işletmenin genel amacını birlikte karşılayabilecek ürünün üretilmesini sağlayacak plan ve programların geliştirilerek uygulanması sağlanmalıdır. Bu genel amaçların sağlanması için ikincil amaçlarda vardır (Pekmezci, 2005). Bunlar:

- Hammadde, enerji, işgücü gibi girdilerde fire ve kayıpları ortadan kaldırmak,
- İşin başında doğru yapılması ile makine, iş gücünden en yüksek verimin sağlanması,
- Düşük kaliteli, kusurlu, bozuk mal sayısını minimuma indirmek,
- Ürünü pazarlama kolaylığı sağlamak,
- İade, bakım, onarım gibi satış sonrası sorunları engellemek,
- Stokları minimum düzeye indirmek
- Ürün kalitesini geliştirmek
- Personelin bilgi ve tecrübesini arttırmak, moralini yükseltmek
- Şirket isminin tüketiciye güvence vermesini sağlamak
- İşçi-işveren ilişkilerini düzenlemek

3.4. Kalitenin Yedi Aracı

İşletmelerde kalite kontrolünde kullanılan metotlar genellikle istatistiksel verilerin kullanılmasıyla elde edilmektedir. Bundan dolayı bu metotlara aynı zamanda İstatistiksel Kalite Kontrol metotları da denilmektedir. Günümüzde istatistik biliminde hızlı gelişmeler olmuş ve bu gelişmeler ışığında sürekli olarak yeni istatistikî metotlar geliştirilmiştir (Deste, 2008).

Bu araçlar 7 grup altında toplanabilir (Çelik, 2015). Bunlar:

1. Çetele Diyagramı
2. Histogram Grafiği
3. Gövde Yaprak Grafiği
4. Pareto Diyagramı
5. Neden Sonuç Diyagramı
6. Hata Yoğunluk Diyagramı
7. Serpilme Diyagramı (Saçılım Grafiği)

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

Deste (2008), çalışmasında kalitenin bu araçların problem sürecindeki işlevlerini Tablo 1’de göstermiştir.

Tablo 1: Problem Çözme Adımları ve Kalite Geliştirme Araçları (Deste, 2008)

Problem Çözme Adımları	Kullanılan Araçlar
Sorunu (karşılıklı) anlamak	Akış diyagramı
Soruna neden olan olguları tespit etmek	Kalite kontrol şemaları
Problemleri belirlemek	Pareto analizi- Histogramlar
Fikir üretmek	Neden-Sonuç diyagramları
Çözüm geliştirmek	Dağılım diyagramları
Uygulama	Kalite kontrol şemaları

4. KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

Kalite Kontrol Süreci için geliştirilen görsel sunum aracının tasarım aşamaları bu bölümde detaylı bir biçimde gösterilmiştir. Görsel Sunum Aracının fonksiyonlarını çalıştırabilmek ve sonuçları görebilmek için işletmeden gelecek verilere ihtiyaç duyulur. Bu veriler hazırlanan veritabanı programındaki tablolarda saklanır. Tablolarda saklanılan veriler, sorgular yardımı ile derlenip gerekli olan çeşitli hesaplamalara tabii tutulur. Hesaplamaların sonuçları yine veritabanı programında tasarlanan raporlar sayesinde tablolar veya grafikler halinde kullanıcıya sunulur. Sunum aracı, Access Veritabanı kullanılarak program haline getirilmiştir. Bu sunum aracı, 3 aşamalı (Hazırlık, Mekanik ve Kaynak Atölyeleri) montaj üretim hattından geçerek üretilen örnek ürünler üzerinde uygulaması yapılarak programın görselleri verilmiştir.

4.1. Veri girişi

Bu işlem programa işlenmesi gereken verilerin veri tabloları ve veri giriş formları sayesinde girilmesini sağlar. Bu işlemin programdaki elemanları ve bu elemanların işleyişi aşağıda sırasıyla açıklanmıştır. Veri girişi Personel, Atölye ve Ürün veri tablosu olarak 3 farklı tablo üzerinde gerçekleştirilmektedir. Personel tablosunun veri sözlüğü Tablo 2’de verilmiştir. Yeni alınan çalışan veya işten ayrılan çalışanların da eklenip çıkarıldığı tablo personel veri deposudur.

Tablo 2: Personel tablosunu veri sözlüğü

Veri Elemanı	Veri Türü	Veri Tanımı
Personel No	Metin	Personel ayırt etmek için her personele verilen Numara.
Adı	Metin	Kayıtlı personelin (personel kişinin) adı.
Soyadı	Metin	Kayıtlı personelin soyadı.
Unvani	Metin	Kayıtlı personelin unvanı.
Birim	Metin	Kayıtlı personelin çalıştığı birim.
Baslama_Tarihi	Tarih/Saat	Kayıtlı personelin işe başlama tarihi.
Dogum_Tarihi	Tarih/Saat	Kayıtlı personelin doğum günü.
Cinsiyet	Metin	Kayıtlı personelin cinsiyeti (Kadın veya Erkek olarak seçilmeli).
Cep_Nosu	Metin	Kayıtlı personele ait cep numarası.
Email	Metin	Kayıtlı personele e-posta adresi.
Resim	Eklenti	Kayıtlı personelin resmi.

Atölye tablonun veri sözlüğü aşağıda Tablo 3’te verilmiştir. İşletmedeki atölyelerin bilgilerinin saklandığı veri deposudur. Tablodaki “Atolye_Sefi” kısmında yazılacak olan personel kodu, personel tablosunda bulunmalı aksi durumda uygulama hata verecektir.

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

Tablo 3: Atölye tablosunun veri sözlüğü

Veri Elemanı	Veri Türü	Veri Tanımı
Atolye_Kodu	Sayı	Her atölyeye ait tanımlanmış atölye numarası.
Atolye	Metin	Atölyeye ait ad.
Atolye_Sefi	Metin	Atölyeden sorumlu olan kişinin personel numarası.
Alan	Metin	Atölyenin büyüklüğü.

Ürün tablosunun veri sözlüğü Tablo 4’te verilmiştir. Üretilen ürünlerinin bilgilerinin saklandığı veri tablosudur.

Tablo 4: Ürün tablosunun veri sözlüğü

Veri Elemanı	Veri Türü	Veri Tanımı
No	Otomatik Sayı	Seri numarası.
Urun_Kodu	Metin	Her ürüne ait tanımlanmış ürün numarası.
Urun_Ismi	Metin	Ürüne ait isim.

Ürün Model Tablosunun veri sözlüğü Tablo 5’te verilmiştir. Bu tablo, ürün Model bilgilerin saklandığı veri tablosudur. Tablodaki “Urun Kodu” kısmında yazılacak olan ürün kodu, Ürünler tablosunda bulunmalı aksi durumda uygulama hata verecektir.

Tablo 5: Ürün Model tablosunun veri sözlüğü

Veri Elemanı	Veri Türü	Veri Tanımı
No	Otomatik Sayı	Seri numarası.
Model_Kodu	Metin	Her modele ait tanımlanmış model numarası.
Model_Ismi	Metin	Modele ait isim.
Urun_Kodu	Metin	Modelin ait olduğu ürünün kodu.
Resim	Eklenti	Modele ait resim.

Aylar tablosunun veri sözlüğü Tablo 6’da verilmiştir. Hata bildirim raporların veri girişi yapıldığında bu bildirimlerin tarihleri de yazılmalıdır. Daha sonra bu tarihleri kullanarak aylık raporlar oluşturulduğunda ayların Türkçe’deki ismine ihtiyaç duyulacak dolayısı ile bu verileri saklamakta yarar vardır. Bu tabloya veri girişi tek seferlik yapılmıştır.

Tablo 6: Aylar tablosunun veri sözlüğü

Veri Elemanı	Veri Türü	Veri Tanımı
Ay_Kodu	Sayı	Ayın yılın kaçınıcı ay olduğu.
Ay	Metin	Ayın Türkçe ’deki ismi.

Hatalar tablosunun Veri deposunun veri sözlüğü Tablo 7’de verilmiştir. Üretim atölyelerinde sıkça rastlanan hatalar belirlenmekte ve rastlandığı atölye bazında gruplandırılmaktadır. Çok nadir rastlanan hatalar ise diğer olarak adlandırılmış ve bu veri deposunda saklanmaktadır. Modellerde tespit edilen hataların nerde daha fazla olduğunu görebilmek için göz atılacak raporların tasarımında çapraz tablo sorgusu kullanıldığından hata türlerinin sayısının sürekli sabit olması gerekmektedir. Dolayısı ile bu tabloya gerek duyulmuştur. Daha kolay sorguların tasarlanması için hatalara kodlar tanımlanmıştır. Bu tabloya veri girişi tek seferlik yapılmıştır.

Tablo 7: Hatalar tablosunun veri sözlüğü

Veri Elemanı	Veri Türü	Veri Tanımı
Hata_Nedeni	Metin	Sık sık yapılan hatalar.
Atolye_Kodu	Sayı	Hatanın yapıldığı atölyenin numarası.
Hata_Kodu	Metin	Hataya ait tanımlanmış kod.

Rastlanan hatalar hata bildirim raporu şeklinde kalite kontrol birimine gelmektedir. Bu raporların bilgileri kalite kontrol tablosunda saklanmaktadır. Bu veri deposuna ait veri sözlüğü Tablo 8’de verilmiştir. Tablodaki “Calisan Kodu” kısmında yazılacak olan personel, personel tablosunda

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

bulunmalıdır aksi durumda uygulama hata verecektir. Aynı durum “Model Kodu” ve “Hata Nedeni” için de geçerlidir.

Tablo 8: Kalite Kontrol sonuçları tablosunun veri sözlüğü

Veri Elemanı	Veri Türü	Veri Tanımı
Kontrol_Kodu	Otomatik Sayı	Seri numarası.
Çalışan_Kodu	Metin	Hatayı bildiren çalışana ait personel numarası.
Tarih	Tarih/Saat	Hata bildirim yapıldığı tarih.
Rapor_No	Metin	Hata bildirim raporun seri numarası.
Model_Kodu	Metin	Hatalı parçanın model numarası.
Hata_Nedeni	Metin	Hatanın nedeni.
Hatta_duzeltildi mi	Metin	Hatanın düzeltilip düzeltilmediği.
Acıklama	Metin	Hata ile ilgili herhangi bir açıklama varsa.
Is_Gucu_Kaybi	Sayı	Hatayı düzeltmek için harcanan adam saat işçilik.
Vardiya	Metin	Hatanın gerçekleştiği vardiya.
Rapor_Resmi	Eklenti	Hataya ait herhangi bir resim varsa.

Üretim Tablosunun veri sözlüğü aşağıda Tablo 9’da verilmiştir. Ürün Modellerine ait aylık üretim hacmi ve işçilik hacmini içeren tablodur. Bu tablodan faydalanarak üretimin yüzde olarak hata oranı hesaplanabilecektir. Tablodaki “Model Kodu” kısmında yazılacak olan model kodu, Modeller tablosunda bulunmalı aksi durumda uygulama hata verecektir. Bu tablodaki “Toplam Ölçüm Sayısı” sütunu hesaplatılmış sütunlar olduğundan bu sütunlara veri girişi izin verilmemektedir.

Tablo 9: Üretim tablosunun veri sözlüğü

Veri Elemanı	Veri Türü	Veri Tanımı
No	Otomatik Sayı	Seri numarası.
Yil	Sayı	Üretim yapılan yıl.
Ay	Sayı	Üretim yapılan ay.
Model_Kodu	Metin	Üretim yapılan modelin kodu.
Uretim_Adedi	Sayı	Girilen yıl, ay, ve modele göre ilgili atölyedeki üretim hacmi (adet).
Makine_Olcum_Sayisi	Sayı	Girilen yıl, ay ve modele göre ilgili atölyedeki birim ürün ölçüm sayısı.
Toplam_Olcum_Sayisi	Hesaplanmış	Girilen yıl, ay ve modele göre ilgili atölyedeki toplam ölçüm sayısı (üretim hacmi*birim ürün ölçüm sayısı).
Iscilik	Sayı	Girilen yıl, ay ve modele göre ilgili atölyede harcanan adam saat işçilik miktarı.

İşçilik Ücretleri Tablosunun veri sözlüğü aşağıda Tablo 10’da verilmiştir. Aylık atölyelere ait adam-saat işçilik ücreti bu tabloda saklanmaktadır. Hataları düzeltmek için harcanan işgücü işletmeye maddi olarak ne kadar kayba yol açtığını görebilmek için bu bilgiye ihtiyaç duyulmuştur.

Tablo 10: İşçilik ücretleri tablosunun veri sözlüğü

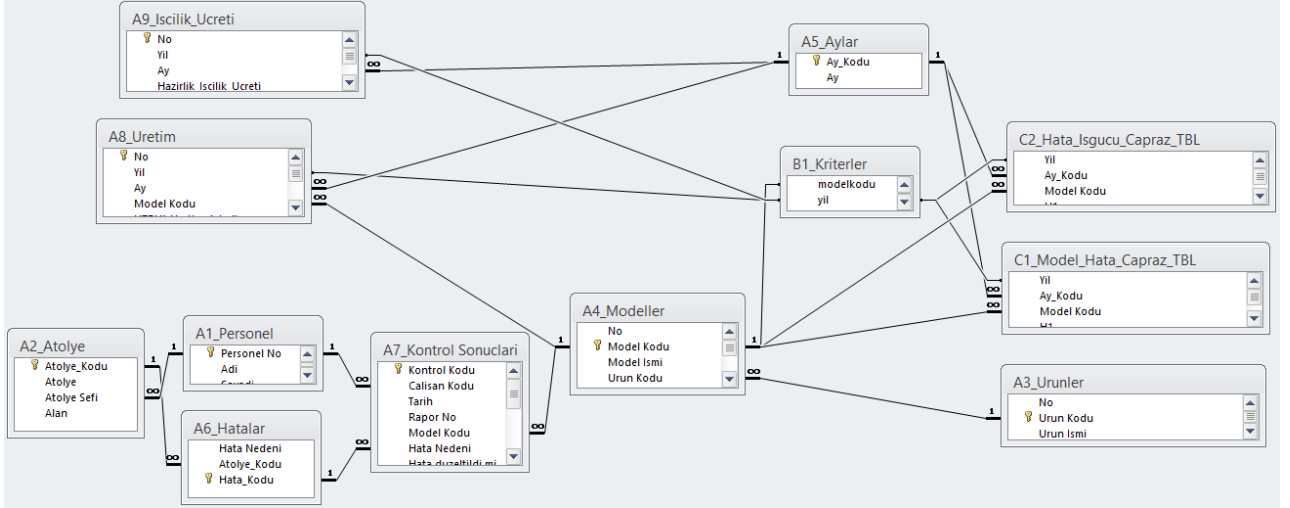
Veri Elemanı	Veri Türü	Veri Tanımı
No	Otomatik Sayı	Seri numarası.
Yil	Sayı	Yapılan İşçiliğin yılı.
Ay	Sayı	Yapılan işçiliğin ayı.
Iscilik_Ucreti	Sayı	İlgili atölyeye ait adam saat işçilik ücreti.

Bu tablolara veri girişi yapmak için iki seçenek sunulmuştur. Uygulamanın bulunduğu dosyada yer alan “veri_ekle.xlsx” adlı Excel dosyasındaki “Urunler”, “Personel” ve “Atolye” adlı sayfadaki veriler bu tablolara transfer edilebilir. Aynı zamanda veri giriş formları kullanarak da tablolara veri girişi yapılabilmektedir.

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

4.2. Varlık İlişki Diyagramı

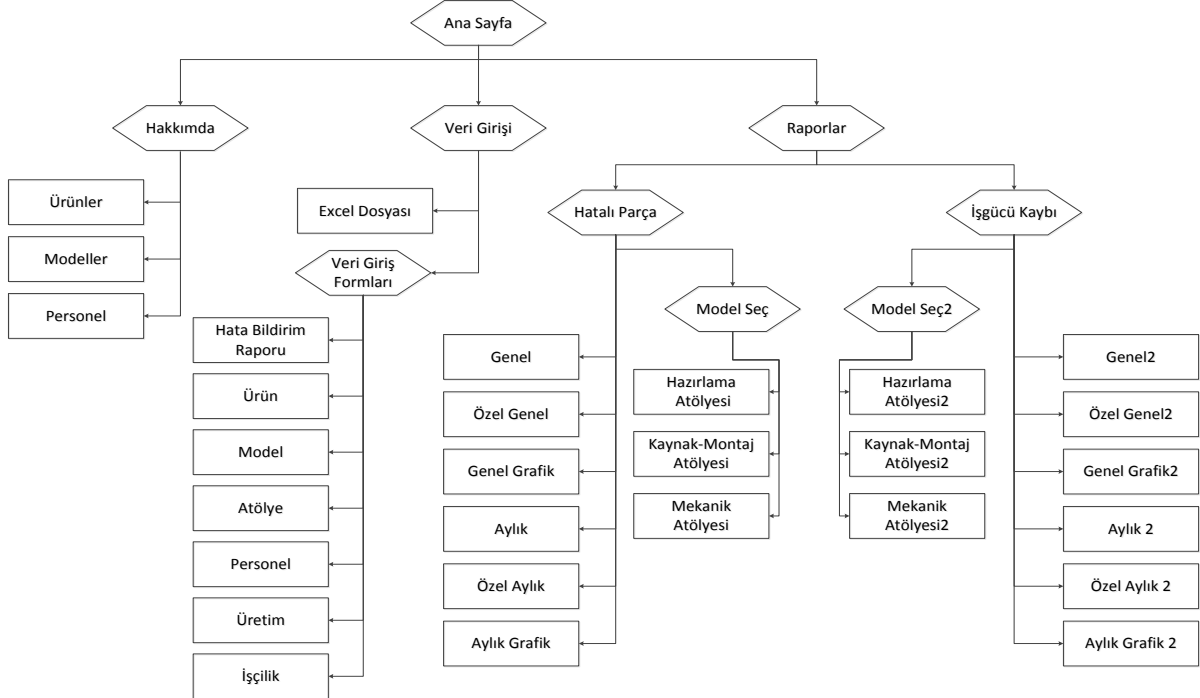
Bir önceki bölümde detaylıca anlatılan veri depoları ve bazı hesaplamalar için sonradan sistem tarafından doldurulacak diğer veri depoların, Varlık İlişki Diyagramı (VAD) aşağıda Şekil 1’de gösterilmiştir.



Şekil 1: Veri depoların varlık ilişki diyagramı

4.3. Kullanıcı Arayüzü

Geliştirilen uygulamanın kullanıcı ara yüzünün hiyerarşik düzeni Şekil 2’te verilmiştir. Bu hiyerarşik düzene göre güvenlik amacı ile öncelikle kullanıcıya üye girişi yaptırılmakta ve Hakkında, Veri Girişi ve Raporlar modüllerinin yer aldığı ana sayfa üye girişi ile sunulmaktadır.



Şekil 2: Uygulamanın hiyerarşik düzeni

4.3.1. Üye Girişi

Kullanıcı ara yüzü ekranı üye girişi ekranı ile başlamaktadır. Üst yönetim tarafından erişime izin verilmiş bireylerin dışında başka kimsenin bilgilere ulaşma riskini azaltarak işletmenin gizlilik

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

politikasını sağlamak amacıyla üye girişi ekranına ihtiyaç duyulmuştur. Kullanıcının şifresini unuttuğu takdirde şifre değiştirme şansına sahip bir sistem kurulmuştur. Aynı zamanda yeni üyelik talebinde de bulunulabilir. Yeni üyelik kabul yetkisi sadece üst kullanıcıya tanımlanmıştır. Şifre değiştirme fonksiyonu ise bireyin üyeliğini oluşturulduğu zamanda seçtiği güvenlik sorusuna doğru cevap verdiği takdirde mümkün kılınabilir. Üyelerin bilgileri “Güvenlik” tablosunda yer almaktadır. Üye girişi ile ilgili kullanılabilir formlar Şekil 3’te gösterilmiştir.

The image shows three screenshots of a web application interface. The first screenshot, titled "Üye Girişi", shows a login form with fields for "Kullanıcı Adı" (Username) and "Şifre" (Password), a "GİRİŞ YAP" (Login) button, and a "Şifremi Unuttum" (Forgot my password) link. The second screenshot, titled "Şifre Değiştir", shows a password change form with fields for "Kullanıcı Adı" (Username), "İlk arabınızın markası neydi?" (What was the first car brand you owned?), "Yeni Şifre" (New Password), and an "İleri" (Next) button. The third screenshot, titled "Yeni Üye", shows a new user registration form with fields for "Üst Kullanıcı adı" (Parent Username), "Şifre" (Password), "Kullanıcı adı" (Username), "Tipi" (Type), "Güvenlik Sorusu" (Security Question), "Cevap" (Answer), and "Şifre" (Password), along with "Giris" (Login) and "Üye Yap" (Register) buttons.

Şekil 3: Üye girişi, şifre değiştirme ve yeni üye tanımlama ekranı

4.3.2. Hakkında Modülü

Üye girişi başarılı bir şekilde yapıldıktan sonra kullanıcıya Ana ekran sunulmaktadır. Ana ekranda ilk modülde yer alan “Hakkında” sekmesine bağlı olarak sırası ile “Ürünler”, “Modeller” ve “Personel” alt sekmeler bulunmaktadır. Bu alt sekmeler tanımlanmış ürünler, modeller ve personel hakkında bilgi vermekte olup kullanıcıya sunulan bilgiyi Excel ve PDF dokümanı olarak indirebilme seçenekleri de sunmaktadır. Örnek ürünler, modeller ve personel bilgi ekranları sırasıyla Şekil 4, Şekil 5, ve Şekil 6’da gösterilmiştir.

KALİTE KONTROL BİRİMİ		
HAKKIMDA	VERİ GİRİŞİ	RAPORLAR
ÜRÜNLER	MODELLER	PERSONEL
No	ÜRÜN KODU	ÜRÜN İSMİ
56	PRD9	PRODUCT 9
55	PRD8	PRODUCT 8
54	PRD7	PRODUCT 7
53	PRD6	PRODUCT 6
52	PRD5	PRODUCT 5
51	PRD4	PRODUCT 4
50	PRD3	PRODUCT 3
49	PRD2	PRODUCT 2
48	PRD1	PRODUCT 1

Şekil 4: Ürünler hakkında bilgi ekranı


İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

KALİTE KONTROL BİRİMİ

HAKKIMDA VERİ GİRİŞİ RAPORLAR
ÜRÜNLER MODELLER PERSONEL

No	44	
MODEL KODU	PRD1_MOD1	
ÜRÜN GRUBU	PRODUCT 1	
No	45	
MODEL KODU	PRD1_MOD2	
ÜRÜN GRUBU	PRODUCT 1	
No	46	
MODEL KODU	PRD1_MOD3	
ÜRÜN GRUBU	PRODUCT 1	
No	47	
MODEL KODU	PRD1_MOD4	
ÜRÜN GRUBU	PRODUCT 1	
No	48	
MODEL KODU	PRD1_MOD5	
ÜRÜN GRUBU	PRODUCT 1	

İNDİR



Şekil 5: Modeller hakkında bilgi ekranı

KSG KALİTE KONTROL BİRİMİ

HAKKIMDA VERİ GİRİŞİ RAPORLAR
ÜRÜNLER MODELLER PERSONEL

P.No		
AD		
SOYAD		
CİNSİYET		
YAŞ		
KIDEM		
ÜNVANI		
BİRİM		
CEP		
E MAİL		

Şekil 6: Personel hakkında bilgi ekranı

4.3.3. Veri Giriş Modülü

“Veri girişi” modülüne bağlı olarak iki alt sekme bulunmaktadır. Birisi klavyeden veri girmeyi sağlarken diğeri Excel dosyasından veri aktarma seçeneği sunmaktadır. Excel’den veri aktarırken aynı zamanda sistemin verileri sıfırlamak istenip istenmediğini de sormakta olup seçildiği takdirde veri aktarmadan önce kayıtlı verileri silip yeni veriyi kaydedecektir. Şekil 7’de veri giriş modülü ana sayfası gösterilmiştir. Örnek model ve hata bildirim veri giriş formu Şekil 8 ve Şekil 9’da sırası ile gösterilmiştir.

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

KALİTE KONTROL BİRİMİ

HAKKIMDA VERİ GİRİŞİ RAPORLAR

Excel Dosyasından Veri Girişi Yap Veri Giriş Formlarından Veri Girişi Yap

Mevcut verilerin silinmesini istiyorum.

HATA RAPORU

ÜRÜN VERİ GİRİŞİ

MODEL VERİ GİRİŞİ

PERSONEL VERİ GİRİŞİ

ATÖLYE VERİ GİRİŞİ

ÜRETİM VERİ GİRİŞİ

İşçilik Maliyeti Veri Girişi

Şekil 7: Veri giriş ana sayfası

MODEL VERİ GİRİŞ FORMU

Resim Ekle

Model Kodu

Model İsmi

Ürün Kodu

Şekil 8: Model veri giriş formu

HATA BİLDİRİM VERİ GİRİŞ FORMU

Resim Ekle

Rapor No

Tarih

Personel Kodu

Ürün Kodu

Model Kodu

Atölye

Hata Nedeni

Harcanan İşgücü

Açıklama

Şekil 9: Hata bildirim veri giriş formu

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

4.3.4. Raporlar Modülü

Raporlar modülü, “Hatalı parça” ve “İşgücü kaybı” olarak iki türe ayrılmıştır. Her tür için Genel, Aylık ve Atölye bazlı raporlar hazırlanabilmektedir. Şekil 10’da Raporlar modülünün ana sayfa ve alt sekmeleri göstermektedir.




Şekil 10: Raporlar ana sayfa görünümü

“Genel” hata raporu, her ürün modelinin her atölyedeki hatalı parça bilgisini verip en son sütunda ise toplam hata bilgisini vermektedir. Şekil 11’de “Genel” hata raporunun bir örneği gösterilmiştir. “Özel-Genel” hata raporu ise “Genel” raporun özeti olup, herhangi bir modelin üstüne tıklanırsa o modelin her atölyedeki hatalı parça raporunu hazırlanmaktadır. Şekil 12’de “Özel-Genel” hata raporu için bir örnek gösterilmiştir. Şekil 10’da “Özel-Genel” hata raporu butonunun yanında yer alan grafik simgesi ise “Genel” hata raporunu grafiksel olarak sunmaktadır. Şekil 13’de grafiksel gösterimi için örnek gösterilmiştir.

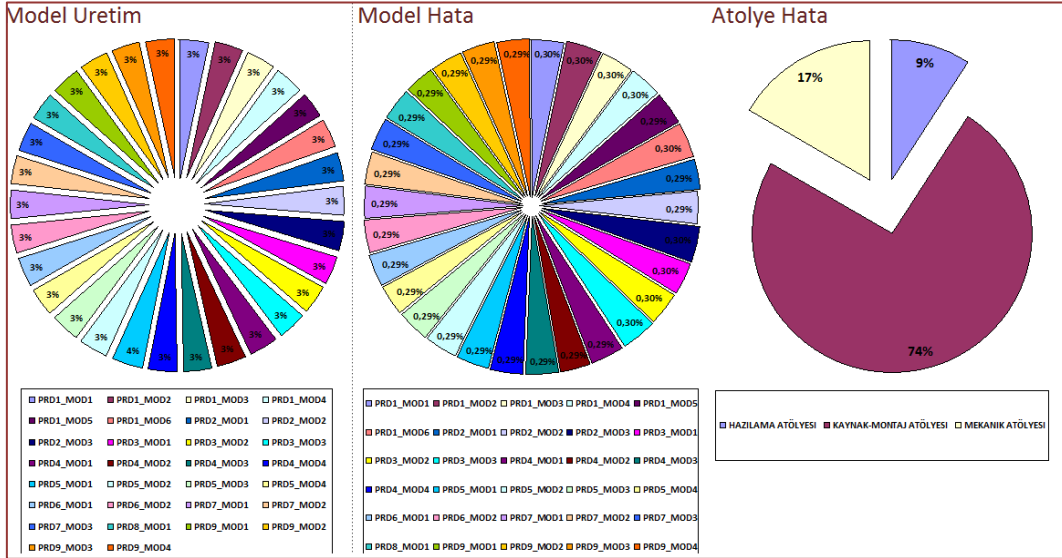
MODEL	HAZIRLAMA ATÖLYESİ			KAYNAK-MONTAJ ATÖLYESİ			MEKANİK ATÖLYESİ			GENEL			
	MİKTAR	# HATA	# ÜRETİM	% HATA	# HATA	# ÜRETİM	% HATA	# HATA	# ÜRETİM	% HATA	# HATA	# ÜRETİM	% HATA
PRD1_MOD1	240	7	4320	%0,16	12	1200	%1,00	6	2880	%0,21	25	8400	%0,30
PRD1_MOD2	240	4	4320	%0,09	13	1200	%1,08	8	2880	%0,28	25	8400	%0,30
PRD1_MOD3	240	7	4320	%0,16	11	1200	%0,92	7	2880	%0,24	25	8400	%0,30
PRD1_MOD4	240	6	4320	%0,14	11	1200	%0,92	8	2880	%0,28	25	8400	%0,30
PRD1_MOD5	220	4	3960	%0,10	12	1100	%1,09	6	2640	%0,23	22	7700	%0,29
PRD1_MOD6	240	4	4320	%0,09	14	1200	%1,17	7	2880	%0,24	25	8400	%0,30
PRD2_MOD1	240	4	4320	%0,09	12	1200	%1,00	8	2880	%0,28	24	8400	%0,29
PRD2_MOD2	240	6	4320	%0,14	10	1200	%0,83	8	2880	%0,28	24	8400	%0,29
PRD2_MOD3	240	7	4320	%0,16	12	1200	%1,00	6	2880	%0,21	25	8400	%0,30
PRD3_MOD1	240	5	4320	%0,12	14	1200	%1,17	6	2880	%0,21	25	8400	%0,30
PRD3_MOD2	240	5	4320	%0,12	14	1200	%1,17	6	2880	%0,21	25	8400	%0,30
PRD3_MOD3	240	7	4320	%0,16	12	1200	%1,00	6	2880	%0,21	25	8400	%0,30
PRD4_MOD1	240	4	4320	%0,09	13	1200	%1,08	7	2880	%0,24	24	8400	%0,29
PRD4_MOD2	240	7	4320	%0,16	10	1200	%0,83	7	2880	%0,24	24	8400	%0,29
PRD4_MOD3	240	7	4320	%0,16	11	1200	%0,92	6	2880	%0,21	24	8400	%0,29
PRD4_MOD4	240	5	4320	%0,12	13	1200	%1,08	6	2880	%0,21	24	8400	%0,29
PRD5_MOD1	260	4	4680	%0,09	14	1300	%1,08	8	3120	%0,26	26	9100	%0,29
PRD5_MOD2	240	6	4320	%0,14	11	1200	%0,92	7	2880	%0,24	24	8400	%0,29
PRD5_MOD3	240	5	4320	%0,12	13	1200	%1,08	6	2880	%0,21	24	8400	%0,29
PRD5_MOD4	240	7	4320	%0,16	11	1200	%0,92	6	2880	%0,21	24	8400	%0,29
PRD6_MOD1	240	4	4320	%0,09	14	1200	%1,17	6	2880	%0,21	24	8400	%0,29
PRD6_MOD2	240	7	4320	%0,16	11	1200	%0,92	6	2880	%0,21	24	8400	%0,29
PRD7_MOD1	240	6	4320	%0,14	12	1200	%1,00	6	2880	%0,21	24	8400	%0,29
PRD7_MOD2	240	4	4320	%0,09	13	1200	%1,08	7	2880	%0,24	24	8400	%0,29
PRD7_MOD3	240	6	4320	%0,14	11	1200	%0,92	7	2880	%0,24	24	8400	%0,29
PRD8_MOD1	240	4	4320	%0,09	14	1200	%1,17	6	2880	%0,21	24	8400	%0,29
PRD9_MOD1	240	7	4320	%0,16	11	1200	%0,92	6	2880	%0,21	24	8400	%0,29
PRD9_MOD2	240	6	4320	%0,14	11	1200	%0,92	7	2880	%0,24	24	8400	%0,29
PRD9_MOD3	240	4	4320	%0,09	13	1200	%1,08	7	2880	%0,24	24	8400	%0,29
PRD9_MOD4	240	5	4320	%0,12	13	1200	%1,08	6	2880	%0,21	24	8400	%0,29
Toplam	7200	164	129600	%0,13	366	36000	%1,02	199	86400	%0,23	729	252000	%0,29

Şekil 11: Genel hata raporu

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI



Şekil 12: Özel-Genel hata raporu




Şekil 13: Genel hata grafik gösterimi

Aylık raporlar ise her ayın her atölyedeki ve toplamdaki hatalı parça üretimi hakkında bilgi sunmaktadır. Şekil 14’de aylık genel hata raporu için bir örnek gösterilmiştir. “Özel-Aylık” ise her ayın toplamdaki hatalı parça üretim hakkında bilgi verip istenilen ayın üzerinde tıklanınca o ayın “Genel” raporunu göstermektedir. Şekil 15’de “Özel-Aylık” için bir örnek gösterilmiştir. Genel kısmında olduğu gibi aylık raporu için de grafiksel gösterimi mevcuttur. Şekil 16’da aylık hatalı parça için grafiksel gösteriminin bir örneği gösterilmiştir.

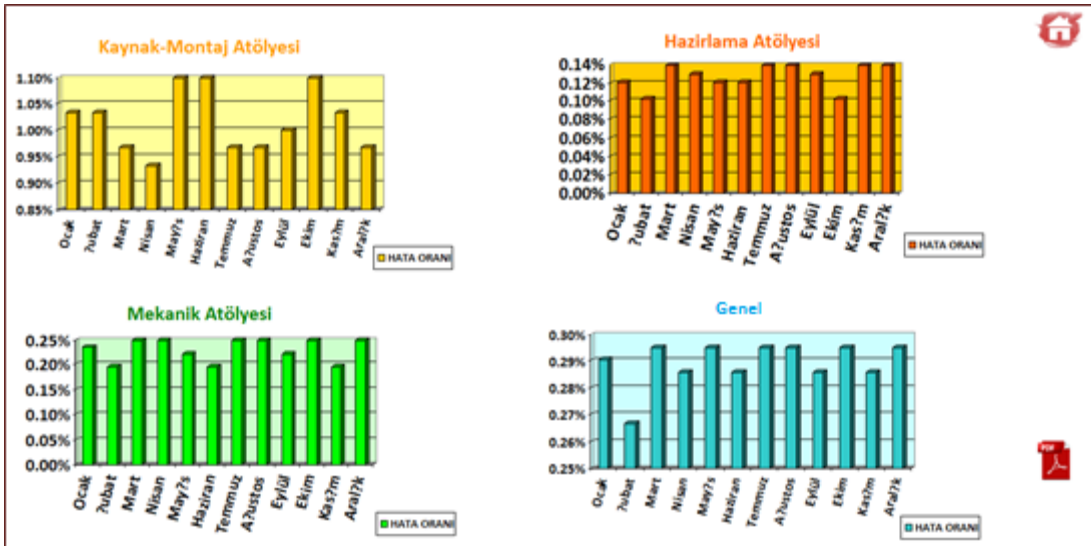
İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

Ay	HAZIRLIK ATÖLYESİ			KAYNAK-MONTAJ ATÖLYESİ			MEKANİK ATÖLYESİ			GENEL			
	MİKTAR	# HATA	# ÜRETİM	% HATA	# HATA	# ÜRETİM	% HATA	# HATA	# ÜRETİM	% HATA	# HATA	# ÜRETİM	% HATA
Ağustos	600	15	10800	%0,14	29	3000	%0,97	18	7200	%0,25	62	21000	%0,30
Aralık	600	15	10800	%0,14	29	3000	%0,97	18	7200	%0,25	62	21000	%0,30
Ekim	600	11	10800	%0,10	33	3000	%1,10	18	7200	%0,25	62	21000	%0,30
Eylül	600	14	10800	%0,13	30	3000	%1,00	16	7200	%0,22	60	21000	%0,29
Haziran	600	13	10800	%0,12	33	3000	%1,10	14	7200	%0,19	60	21000	%0,29
Kasım	600	15	10800	%0,14	31	3000	%1,03	14	7200	%0,19	60	21000	%0,29
Mart	600	15	10800	%0,14	29	3000	%0,97	18	7200	%0,25	62	21000	%0,30
Mayıs	600	13	10800	%0,12	33	3000	%1,10	16	7200	%0,22	62	21000	%0,30
Nisan	600	14	10800	%0,13	28	3000	%0,93	18	7200	%0,25	60	21000	%0,29
Ocak	600	13	10800	%0,12	31	3000	%1,03	17	7200	%0,24	61	21000	%0,29
Şubat	600	11	10800	%0,10	31	3000	%1,03	14	7200	%0,19	56	21000	%0,27
Temmuz	600	15	10800	%0,14	29	3000	%0,97	18	7200	%0,25	62	21000	%0,30
Toplam	7200	164	129600	%0,13	366	36000	%1,02	199	86400	%0,23	729	252000	%0,29

Şekil 14: Aylık genel hata raporu



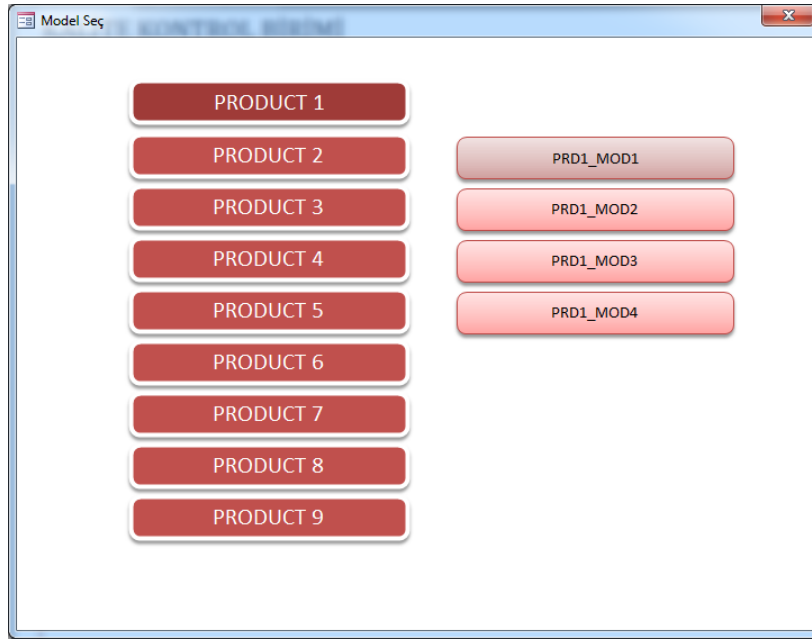
Şekil 15: Aylık özel hata raporu



Şekil 16: Aylık hata raporu grafikleri

“Model Atölye” rapor türünde, kullanıcıdan ilk başta bir ürün seçmesi ve seçtiği ürünün bir modelini seçmesi istenmektedir. Şekil 17’de model seçme ekranı gösterilmiştir. Bir model seçildikten sonra o modele ait her atölyenin raporu ayrı sekmelerde sunulacaktır. Şekil 18’de rastgele seçilen bir model için bir rapor örneği gösterilmiştir.

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI



Şekil 17: Ürün modeli seçme ekranı

ATÖLYELERİN AYLIK HATA ORANLARI								Model	ÜRÜN
								PRD1_MOD1	Güncelle
HAZIRLAMA ATÖLYESİ			KAYNAK-MONTAJ ATÖLYESİ			MEKANİK ATÖLYESİ			
Ay	CNC Kesim Hatası	CNC Kesim Yarası	Kaynak Ağız Hatası	Abkant Büküm Hatası	Diğer	Toplam Hata	Toplam Olcum Sayısı	Hata Yuzdesi	
Ocak	0	0	0	1	0	1	360	%0,28	
Şubat	0	0	0	0	0	0	360	%0,00	
Mart	0	0	0	0	0	0	360	%0,00	
Nisan	0	0	0	0	0	0	360	%0,00	
Mayıs	0	1	0	0	1	2	360	%0,56	
Haziran	0	0	0	0	0	0	360	%0,00	
Temmuz	0	0	0	1	0	1	360	%0,28	
Ağustos	0	0	0	0	0	0	360	%0,00	
Eylül	0	0	0	0	0	0	360	%0,00	
Ekim	0	0	0	0	1	1	360	%0,28	
Kasım	0	1	0	0	0	1	360	%0,28	
Aralık	0	0	0	1	0	1	360	%0,28	
Toplam	0	2	0	3	2	7	4320	%0,16	

Şekil 18: Ürün Model-Atölye raporu

İşgücü kayıp raporları da hatalı parça raporlarının benzer yapıya sahip olup sadece veri olarak hatalı parça sayısı yerine o hatalar neticesinde meydana gelen işgücü kaybını içermektedir. Aynı türden raporlar olduğundan tekrar açıklamalar ve görsellerden kaçınılmıştır.

5. SONUÇ VE DEĞERLENDİRME

Bu çalışmada, kalite kontrol sürecinin kolay takip edilmesi ve üst yönetimin istediği bilgilere kolayca ulaşmasına yönelik kalite kontrol süreci için görsel sunum aracı geliştirilmiştir. Yapılan çalışmanın klasik yöntemlerden ayrılıp veri tabanı kullanılarak oluşturulan bir program olmasının işletmelere olan katkısı ortaya konmuştur. İşletmelerin mevcut kontrol süreçlerinde istenilen her kriterin teker teker farklı kaynaklardan toplanıp bir Excel dosyasında birleşmesi kalite kontrolünü ve takibini oldukça zorlaştırmaktadır. Çalışmanın sonucunda bu verilerin düzenli olarak girilebileceği ve daha sonrasında otomatik olarak girilen veriler sonucu istenilen çeşitli raporların oluşması sağlanmıştır. Bu raporlar çok çeşitli raporlar olmakla beraber her biri görsel olarak da ortaya konmuştur. Sistemde ayrıca yeni eklemeler kolaylıkla yapılmakta ve istenilen farklı özellikteki

İŞLETMELERİN KALİTE KONTROL SÜRECİ İÇİN GÖRSEL SUNUM ARACI TASARIMI

raporlar da hazırlanabilmektedir. Geliştirilen görsel araç içerisinde hazırlanan bu raporların tek seferlik hazırlanmasından sonra bunu otomatik olarak sonraki süreçte gerçekleştirebilecek yapıya sahiptir.

Programın işletmeler tarafından adaptasyon süreci ve kullanıma tam geçilmesi durumu biraz zaman alacaktır. Programın kullanılacağı işletmelerde Microsoft Access programına tam anlamıyla hakim olunmaması zaman zaman çeşitli sorunlar çıkarabilecektir. Ancak yapılacak eğitim ve programın zaman içerisinde yoğun şekilde kullanılması bu sorunu ortadan kaldıracaktır. Programın kullanılmasında bir başka etken veri toplanmasıdır. İşletmeden toplanan verilerin doğru ve eksiksiz olması gerekmektedir. Yanlış toplanan veya programa yanlış girilen veriler sonucunda haliyle program yanlış sonuçlar verecektir. Bir işletmenin gelişimi yalınlaşmasıyla çoğu zaman doğru orantılıdır. Yalınlaşmanın bir süreci de işletmenin görselleştirmesidir. Yani işletmede sonuç ve verilerin karmaşık sayılar yerine daha sade ve anlaşılır olacak görsel bir şekilde ifade edilmesi gerekmektedir.

Geliştirilen bu programa ek olarak kalite kontrol yöntemlerinden daha fazla yararlanılması işletmelerin yararına olacaktır. Mevcutta birçok işletme reaktif bir yaklaşım sergilemektedir. Bunun proaktif olması işletmeyi kara geçirecektir.

6. KAYNAKÇA

Akbul K., (2010). Kalite Kontrol Grafikleri ve Bir ERP Programı olan CANIAS ERP’de Kalite Kontrol Grafikleri Uygulamaları, Yüksel Lisans Tezi, İSTANBUL.

Çelik M., (2015). İstatistiksel Kalite Kontrol Yöntemlerinin Karşılaştırmalı Olarak İncelenmesi, Yüksek Lisans Tezi, ADANA.

Deste M., (2008). Kalite Kontrol Yöntemleri ve Uygulamada Karşılaşılan Sorunlar (Malatya Organize Sanayi Bölgesindeki Üretici İşletmeler Üzerine Bir Uygulama), Yüksek Lisans Tezi, MALATYA.

Gökkaya A. G., (2008). Faaliyet Alanı Bayan İç Giyim Üretimi Olan Hazır Giyim İşletmelerinde Kullanılan Kalite Kontrol Parametreleri ve Üretim Sürecinde Kalite Kontrol, Yüksek Lisans Tezi, KONYA.

Güleş H.K., (1990). Sanayi İşletmelerinde Kalite Kontrolü ve TUMOSAN A.Ş.’nde Kalite Kontrolü Uygulaması, Yüksek Lisans Tezi, KONYA.

Kayaalp İ. D., (2007). Konfeksiyon İşletmelerinde Kalitenin İyileştirilmesi Amacıyla İstatistiksel Kalite Kontrol Yöntemlerinin Kullanılması Üzerine Bir Araştırma, Doktora Tezi, İZMİR

Koçak E. K., (2013). İstanbul Nakış Sanayi İşletmelerinde Üretim Sürecindeki Kalite Kontrol Uygulamaları Üzerine Bir Araştırma, Doktora Tezi, ANKARA.

Özkale M. R., (2004). İstatistiksel Kalite Kontrol Yöntemleri ve Uygulamalar, Yüksek Lisans Tezi, ADANA.

Pekmezci A., (2005). İstatistiksel Kalite Kontrol Yöntemleri ve Uygulaması, Yüksek Lisans Tezi, MUĞLA.

Yıldırım S., (2015). Giriş Kalite Süreçlerinde Kabul Örneklemesine Yönelik Bir Metodoloji: Beyaz Eşya Endüstrisinde Bir Uygulama, Yüksek Lisans Tezi, İSTANBUL.

Yüksel M., (1992). Kalite Kontrolünde Parametre Analizi ve Markov Zincirlerinin Kalite Kontrolü Problemine Bir Uygulaması, Doktora Tezi, İSTANBUL.

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?

İhsan Özer

Pamukkale Üniversitesi, Pamukkale, Denizli

ihsano@pau.edu.tr

1. GİRİŞ

Günümüz dünyasında ebeveynlerin ve çocukların en büyük kaygılarından birisi sanal dünya ve oyun bağımlılığıdır. Bugün maalesef sanal ve mobil oyunlar çocuklarımızı her geçen gün daha fazla esir almaktadır. Gerek ebeveynler gerekse okul bu konuda ne kadar çalışma yaparsa yapsın maalesef çocuklarımızın sanal dünyaya ve internete olan bağımlılığına olumlu yönde çok az katkı sağlayabilmektedir.

Bu bölümde ilgili sıkıntıya programsal açıdan nasıl olumlu yönde katkı sağlanabileceği incelenecektir.

2. ÇOCUKLARIN DOĞASI

2.1. Çocukları Anlamak

Yapılan en büyük hatanın çocukları ve gençleri anlamamaktan kaynaklandığını düşünebiliriz. Nesiller ne kadar değişirse değişsin çocukların doğası pek değişmez bizler de çocukken ailemiz ne kadar baskı uygularsa uygulasin her fırsatta kendimizi oyun salonlarına atıp bütün harçlıklarımızı jetonlara harcamadık mı?

2.2. Peki Ne Yapılabilir?

Baskıyı bir tarafa bırakıp onları anlamaya çalışmalı, kendi çocukluğumuzdan referans alarak bir çocuğun sosyalleşme dışında en azından ders çalışma sorumluluğunu oyun programlarıyla beraber nasıl yürütebiliriz sorusuna odaklanabiliriz.

Yani eğer onları sanal ortam ve oyunlardan uzaklaştıramıyorsak en azından dersi onların istediği formatta sanal ortama taşıyabiliriz.

2.3. Yöntem

Bu bölümde herkesin yakından bildiği popüler bir yarışma programından (Kim Milyoner Olmak İster) referans alınarak, bu programın nasıl yazıldığı, nasıl kullanıldığı ve nasıl geri dönüşler alındığından bahsedilecektir.

3. PROGRAM

3.1. Nasıl Kullanılır?

Program çalıştırıldığında hepimizin yakından bildiği şu ekran açılmaktadır.

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?



Şekil 1: Programın Başlangıç Ekranı

Elbette ses efektleri de çok önemli bir detay olduğundan yarışmadaki sesli ve görsel efektler internette paylaşılan bölümlerinden alınarak program kaynağına kaydedilmiş ve ilgili yerlerde doğru efektler ile öğrencinin odaklanma ve motivasyonu olumlu yönde arttırılmaya çalışılmıştır.

Öğrenci “BAŞLA” butonuna bastığı anda aynen yarışma formatına göre kolaydan zora doğru kendi seviyesinde öğretmenin daha önce programa kaydettiği sorularla karşılaşmaktadır. Örneklerde İlköğretim 1. Sınıf seviyesinde sorular kullanılmıştır.



Şekil 2: Soru Ekranı

Öğrenci sorulara doğru cevap verdikçe tıpkı yarışmadaki gibi adım adım ilerlemektedir.

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?

Kim Milyoner Olmak İster?

Sonraki Soru >>

MİLYONER

9.ayda doğdum diyen biri hangi ayda doğmuştur?

A) mayıs
B) ekim
C) eylül
D) kasım

1.000.000
250.000
125.000
60.000
30.000
15.000
7.500
5.000
3.000
2.000
1.000
500

Şekil 3: Soru Ekranı (Doğru Cevap)

Kim Milyoner Olmak İster?

MİLYONER

Kasabadan büyük,ilden küçük, köyden büyük, ilçe olan aşağıdakilerden hangisidir?

A) köy
B) il
C) mahalle
D) ilçe

1.000.000
250.000
125.000
60.000
30.000
15.000
7.500
5.000
3.000
2.000
1.000
500

Emin misiniz?
SON KARARINIZ MI?
EVET HAYIR

Şekil 4: Son Kararınız mı?

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?

Kim Milyoner Olmak İster?

Tekrar Oyna

MİLYONER

42+36 = ?

A) 73
B) 75
C) 76
D) 78

1.000.000
250.000
125.000
60.000
30.000
15.000
7.500
5.000
3.000
2.000
1.000
500

Şekil 5: Yanlış Cevap

Kim Milyoner Olmak İster?

MİLYONER

"Ağaçların dallarına.....konmuş." cümlesinde noktalı yere aşağıdakilerden hangisini yazmamız uygun olmaz?

A)
B)
C) tavşanlar
D) arılar

1.000.000
250.000
125.000
60.000
30.000
15.000
7.500
5.000
3.000
2.000
1.000
500

Şekil 6: Yüzde Elli Joker Hakkı

Telefon jokeri yerine daha önce kaydedilen soru ile ilgili bir ipucu verilmektedir.

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?

Kim Milyoner Olmak İster?

MİLYONER

"taş- çamur- kum - su" kelimelerini alfabesinin sırasına göre dizdiğimizde ikinci kelime hangisidir?

A) taş

B) su

C) çamur

D) kum

1.000.000

250.000

125.000

60.000

30.000

15.000

7.500

5.000

3.000

2.000

1.000

500

ilk harfe göre k harfi ile başlayan 2, olur

Tamam

Şekil 7: Telefon Jokeri

Kim Milyoner Olmak İster?

MİLYONER

Güneş'ten küçük,Ay'dan büyüğüm .Şeklim de küreye benzer diyen gezegen aşağıdakilerden hangisidir?

A) ay

B) dünya

C) güneş

D) yıldız

1.000.000

250.000

125.000

60.000

30.000

15.000

7.500

5.000

3.000

2.000

1.000

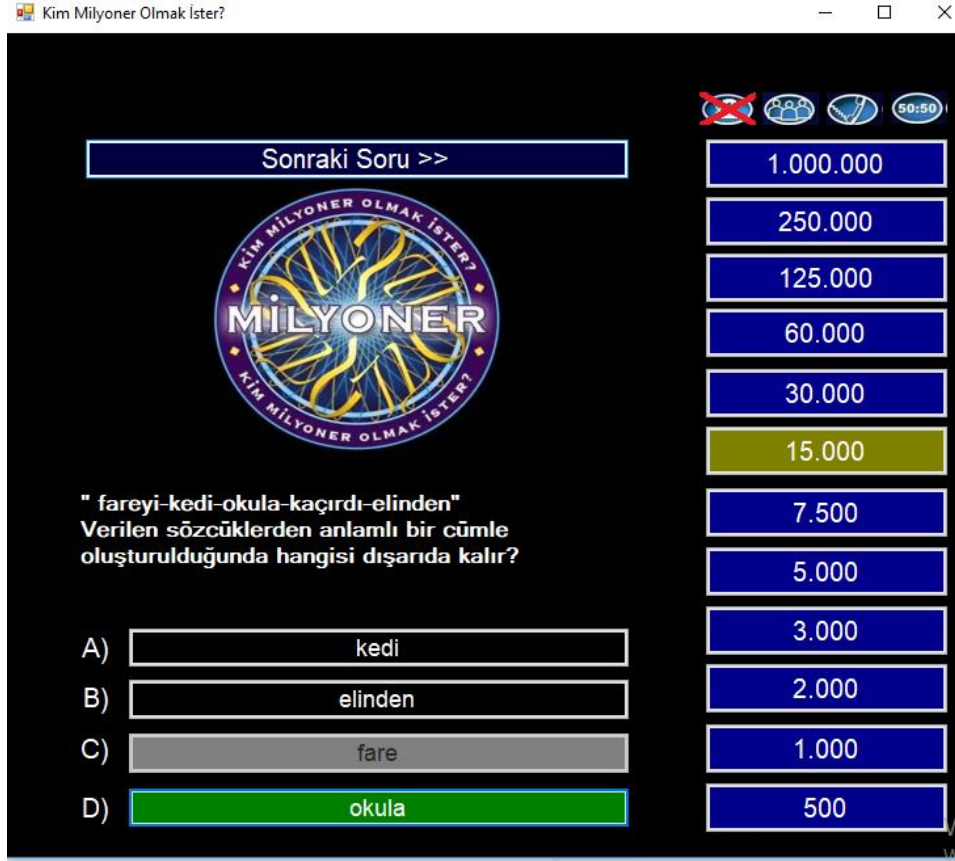
500

Seyircinin Coğunluğu [B] Diyor!

Tamam

Şekil 8: Seyirci Jokeri

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?



Şekil 9: Çift Cevap Jokeri

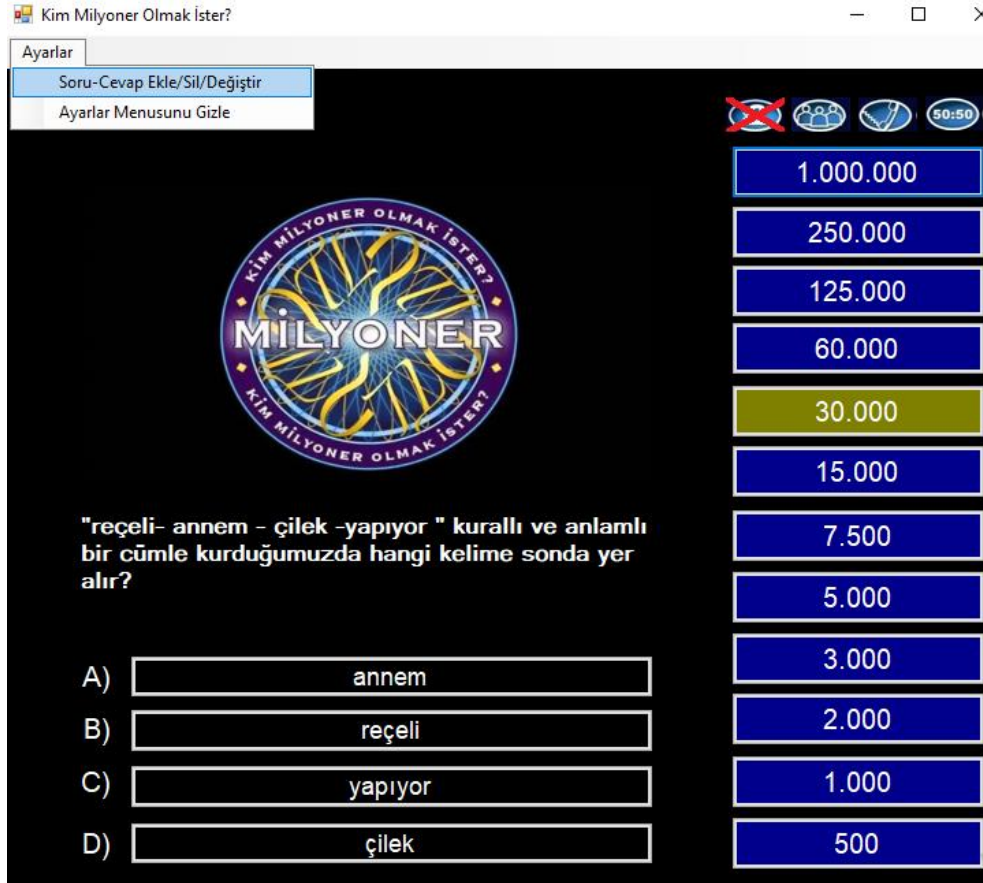
Oyunun bundan sonraki adımları da yarışmanın kuralları ile paralel şekilde devam etmektedir. (Belli bir sorudan sonra sürenin kalkması, 15.000 den sonra çift cevap hakkının eklenmesi, jokerlerin kullanılması vs..)

Ayrıca programın en etkili ve farklı tarafı ise soruların istenildiği gibi değiştirilip eklenebilmesi ve her seviyedeki öğrenciye uyarlanabilmesidir.

Bunun için programa sadece öğretmenin veya sorulara müdahale etmeye yetkili olan kişinin bildiği bir anahtar yerleştirilmiştir ve yetkili kişi o anahtarı girince program soruların düzenlenebildiği ekranı açmakta ve öğretmen bu ekrandan dilediği seviyede dilediği kadar soruyu ekleyip güncelleyebilmektedir.

Öğretmen sırasıyla önce 500, sonra 1.000.000 butonuna bir kez tıklayıp en son milyoner resmine çift tıklarsa "Ayarlar" menüsü açılmakta ve bu menüden sorulara müdahale edip menüyü tekrar gizleyebilmektedir.

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?



Şekil 10: Ayarlar Menusu

Soruların eklenip güncellenebildiği ekran şu şekildedir;

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?

Sorunun Seviyesini Seçiniz

Soruyu Seçiniz

1.000.000
250.000
125.000
60.000
30.000
15.000
7.500
5.000
3.000
2.000
1.000
500

9.ayda doğdum diyen biri hangi ayda doğmuştur?
Atatürk'ün Bandırma Vapuru ile Samsun'a giderek Kurtuluş Savaşı'nı başlattığı günü her yıl hangi bayram?
"Yapıştınca" kelimesi kaç hecelidir?
"Ağaçların dallarına.....konmuş." cümlesinde noktalı yere aşağıdakilerden hangisini yazmamız uygundur?
5+7+3=?
2şer ritmik saydığımızda 6.sırada söylediğimiz sayı nedir?

Sorunun Seviyesini Seçmeyi ve Doğru Cevabı İşaretlemeyi Unutmayınız!

9.ayda doğdum diyen biri hangi ayda doğmuştur?

A) mayıs B) ekim

C) eylül D) kasım

Telefon Jokeri (İpucu)

eylül

Yeni Soru Olarak Ekle Seçtiğim Soruyu Değiştir Seçtiğim Soruyu Sil

Şekil 11: Soru Düzenleme Ekranı

Bu ekrandan öğretmen dilediği gibi sorulara müdahale edebilmektedir. Tabii programa her seviyede ne kadar fazla soru eklenirse yarışma o kadar zevkli olacaktır çünkü program ilgili seviyedeki soruların içerisinden rasgele birini seçip ekrana basmaktadır bu sayede ne kadar fazla soru olursa oyun her oynandığında aynı sorunun çıkmaya ihtimali de o kadar azalmış olur.

3.2. Nasıl Yazıldı?

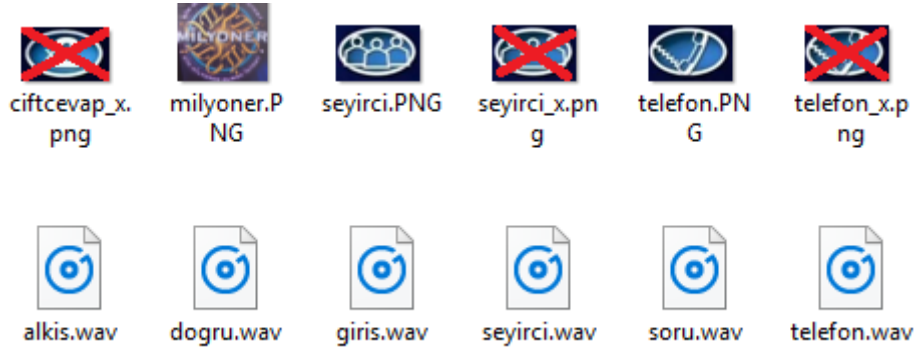
3.2.1. Kullanılan Araçlar

- Microsoft Visual Studio 2012
- C# Programlama Dili
- Access
- SQL Sorhulama Dili

3.2.2. İçerik

Program yazılırken yarışmanın orijinaline paralel olması için internet ortamından yarışma ile ilgili görseller ve ses efektleri alınarak programa kaydedilmiş olup örnek bazı dosyalar aşağıdaki gibidir;

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?



Şekil 12: Kullanılan Görsel ve Ses Efektlerinden Bazıları

Sorular "Access" veritabanında tablolar halinde tutulmaktadır. Bu tablolardaki veriler SQL sorgulama dili ve C# programlama dili ile program tarafından istenilen şekilde kullanılabilir. Tablolarda aşağıdaki gibi birbirleri ile ilişkili veriler tutulmaktadır.

Tablo 1: Sorular Tablosu

soruno	soru	seviyeno	ipucu
53	9.ayda doğdum diyen biri hangi ayda doğdu?	1	eylül
54	Kasabadan büyük,ilden küçük yerleşim yeridir.	2	ilçe
55	Atatürk'ün Bandırma Vapuru ile Sarıyer'e geldiği tarihtir.	1	gençlikle ilgili
56	Güneş'ten küçük,Ay'dan büyüğüm .:.	2	dünya
57	"taş- çamur- kum - su" kelimelerini sıraladığımızda kaç harf düşer?	3	ilk harfe göre k
58	" yastık- yassı-yasak-yaslanma" kelime dizisinde kaç harf düşer?	5	dördüncü harfi
59	"Yapıştırıcı"kelimesi kaç hecelidir?	1	5
60	Aşağıdakilerden hangisi cümle değil?	3	b şıkkı
61	"Tatilde.....gideceğiz." cümlesinde boşlukta hangi kelime gelmelidir?	4	nereye sorusu
62	Aşağıdaki cümlelerden hangisinin soru işareti yanlış kullanılmıştır?	5	nereye-nasıl-n
63	"Ağaçların dallarına.....konmuşlardır." cümlesinde boşlukta hangi kelime gelmelidir?	1	uçmayan
64	"Akşam oldu.....?" cümlesinin soru işareti yanlış kullanılmıştır.	4	mu
65	Aşağıdaki cümlelerin hangisi daha anlamlıdır?	6	kelimeleri say
66	Bütün köy beyaz bir örtüyle kaplanmıştır.	6	kar ne zaman y
67	" fareyi-kedi-okula-kaçırdı-elinden"	7	alakasız olan
68	"reçeli- annem - çilek -yapıyor "	8	eylem oluş har
69	"uzak - yakın' arasındaki ilişkiye benzerdir."	9	zitolan
70	Aşağıdaki sözcüklerden hangisi tek vokal içerir?	8	kalem
71	Aşağıdakilerden hangisinde özel isim kullanılmıştır?	10	hayvanlara tak
73	Aşağıdaki cümlelerin hangisi sebep-sonuç ilişkisi içerir?	11	neden sorusur
74	Hangi noktalama işaretinden sonra köşeli parantez kullanılır?	12	b
75	Aşağıdakilerden hangi ikisi kardeşlerdir?	11	a
76	5+7+3= ?	1	a şıkkı
77	2şer ritmik saydığımızda 6.sırada söylenilen sayı kaçtır?	1	b şıkkı
78	14+9 +2= ?	2	c şıkkı

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?

Tablo 2: Cevaplar Tablosu

cevapno	cevap	soruno	dogrumu
209	mayıs	53	0
210	ekim	53	0
211	eylül	53	1
212	kasım	53	0
213	köy	54	0
214	il	54	0
215	mahalle	54	0
216	ilçe	54	1
217	AtatürküAnma	55	1
218	Zafer Bayramı	55	0
219	Çocuk Bayramı	55	0
220	Cumhuriyet Ba	55	0
221	ay	56	0
222	dünya	56	1
223	güneş	56	0
224	yıldız	56	0
225	taş	57	0
226	su	57	0
227	çamur	57	0
228	kum	57	1

Tablo 3: Seviyeler Tablosu

seviyeno	seviye
1	500
2	1.000
3	2.000
4	3.000
5	5.000
6	7.500
7	15.000
8	30.000
9	60.000
10	125.000
11	250.000
12	1.000.000

Yarışma analiz edilerek program modüler bir yapıya dönüştürülmüştür ve C# programlama dili kullanılarak aşağıdaki şablonda bir "Class" dosyası tasarlanmıştır;

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?

```
class islemler
{
    string bcum = "provider=microsoft.jet.oledb.4.0;" +
        "data source=soru_ve_cevaplar.mdb";
    public islemler()...
    public DataRow rastgele_soru_getir(string seviyeno)...)
    public void soru_sil(string soruno)...)
    public void cevap_degistir(string cevapno, string cevap, string soruno, RadioButton rb)...)
    public void soru_degistir(string soruno, string soru, string seviyeno, string ipucu)...)
    public DataTable cevap_getir(string soruno)...)
    public DataTable soru_getir(string soruno)...)

    public string son_eklenen_soruno()...)
    public void cevap_ekle(string cevap, string soruno, RadioButton rb)...)
    public void soru_ekle(string soru, string seviyeno, string ipucu)...)
    public void listele(string sql, ListBox lb)...)
}
```

Şekil 13: Kullanılan Class Dosyasının Şablonu

Şekildeki class dosyasını kullanan formların şablonları da şu şekildedir;

```
public partial class baslangic : Form
{
    public baslangic()...

    private void baslangic_Load(object sender, EventArgs e)...)

    private void btTekrar_Click(object sender, EventArgs e)...)
}
```

Şekil 14: Başlangıç Formu

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?

```
public partial class Form1 : Form
{
    public Form1()...
    bool yanlis = false;
    int seviyeno = 0;
    islemler islem = new islemler();
    bool a1 = false, a2 = false;
    int sure = 450;
    bool yariyariya = false,ciftcevap=false,seyirci=false,tel=false;
    int cc_say = 0;
    string ipucu;
    public static bool ShowConfirmDialog(string text, string caption)...)

    private void soruCevapEkleSilDeğİştirToolStripMenuItem_Click(object sender, EventArgs e)...)

    private void tbA_TextChanged(object sender, EventArgs e)...)

    private void tbA_MouseClick(object sender, MouseEventArgs e)...)

    private void label3_Click(object sender, EventArgs e)...)

    private void Form1_Load(object sender, EventArgs e)...)

    private void sonraki_soru()...)

    void seviye_kontrol()...)
    private void soru_gelsin()...)

    private void tbA_MouseHover(object sender, EventArgs e)...)

    private void tbA_MouseLeave(object sender, EventArgs e)...
```

Şekil 15: Yarışma Formunun Bir Kısmı

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?

```
public partial class sc : Form
{
    public sc()...

    islemler islem = new islemler();
    private void sc_Load(object sender, EventArgs e)...

    private void btYeni_Click(object sender, EventArgs e)...

    void temizle()...

    private void lbSeviye_SelectedIndexChanged(object sender, EventArgs e)...

    private void sorulari_listele()...

    private void lbSoru_SelectedIndexChanged(object sender, EventArgs e)...

    private void btDegistir_Click(object sender, EventArgs e)...

    private void btSil_Click(object sender, EventArgs e)...
}
```

Şekil 16: Soru Güncelleme Formu

Yukarıdaki program şablonlarında kodun tamamı bulunmamaktadır. Sadece program yazılırken nasıl bir yol izlendiği konusunda bilgi vermek içindir.

3.3. Nasıl Geri Bildirimler Alındı?

Bu programı kullanan öğrenciler izlendiğinde programın ders çalışma üzerindeki olumlu etkisi o kadar net bir şekilde görülmüştür ki zira öğrenciler tenefüs zamanlarında dahi oynamak (ve tabii öğrenmek) için birbirleriyle yarışır hale gelmiştir.

Öyle ki bazı ebeveynlerin bu program sayesinde çocuğun zararlı oyunlara olan bağımlılıklarını azalttığı yönündeki geri bildirimleri dahi olmuştur.

4. SONUÇLAR

Yazılan bu program sayesinde çocukların;

- Eğlendiği
- Eğlenirken öğrendiği
- Oyun oynayarak öğretmenin anlattıklarını tekrar ettiği
- Rekabet güdüsünün güçlendiği
- Soru çözerken zamanı doğru kullanma becerisinin arttığı

net bir şekilde görülmektedir.

5. KAYNAKÇA

- Ulusal televizyon kanallarından ATV ekranlarında yayınlanan “Kim Milyoner Olmak İster” Yarışması ve İlgili Yarışmada Kullanılan Görsel ve Ses Efektleri
- Microsoft Visual Studio 2012
- Access 2003/2007
- C# 7.0

PROGRAMLAMA, EĞİTİM VE ÖĞRETİMDE NASIL FAYDALI BİR ŞEKİLDE KULLANILABİLİR?

- SQL (Sequenced Query Language)

Dipnot: “Kim Milyoner Olmak İster” yarışmasının konsepti, görselleri, ses efektleri ve marka niteliğindeki hiçbir özelliği ticari amaçlı kullanılmamış sadece oyunun öğretmeye etkisi üzerinde çalışmak için kullanılmıştır.

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER

Mihriban Kalkancı

Pamukkale Üniversitesi, Denizli Teknik Bilimler Meslek Yüksekokulu, Denizli, Türkiye.

mkalkanci@pau.edu.tr

1. GİRİŞ

Günümüzde hızla ilerleyen teknolojik gelişmeler tekstil, konfeksiyon ve hazır giyim sektöründe de yaşanmaktadır. Son teknolojik gelişmeler, sektörde hem ürün çeşitliliğini sağlamakta hem de hızlı üretim, ekonomiklik ve verimlilik gibi avantajlarla üreticilere katkı sağlamaktadır.

Tekstil ve konfeksiyon üreticileri, bugün kumaşlarına ve kıyafetlerine değer katmak için çok çeşitli yaratıcı ve ustaca dekoratif teknikleri kullanmaktadır. Bu yeni dekoratif tekniklerin geliştirilmesi, giysi teknolojisindeki son yeniliklerle kolaylaştırılmıştır. Böylece, tasarımcılar ve üreticiler için ekonomik tasarım seçenekleri genişlemiştir. Bu yenilikler doğrudan dijital baskıya, nakışa, konvansiyonel dikişe, süsleme tekniklerine, ısı transferine ve lazer dekorasyona yönelik makinelere odaklanmıştır. Ayrıca, elektronik tekstiller ve akıllı giysilerdeki gelişmeler, giysilerin kullanıcıları için işlevselliğini artırarak, estetik alanın ötesinde giysi dekorasyonunu da sağlamıştır.

Lif, tekstil üretimi ve giyim eşyası üretimi geliştirmekte olan dünyada sanayileşmeye yol açmaktadır. Dünyada yaşanan teknolojik değişiklikler, giysi üretiminin otomasyonunu da teşvik etmektedir. CAD, CAM, üretim yönetimi ve bilgi teknolojisi sistemleri gibi teknolojiler, moda ve tekstil endüstrisinde birçok kolaylığı sağlamaktadır. Bu kolaylıklar aynı zamanda işgücü verimliliğini artırarak toplam üretim maliyetlerini azaltmaktadır [1].

Mobil cihazlar, uygulamalar, sosyal medya ve bağlantı teknolojilerinin birbirine bağlı biçimde yükselişi geçtiğimiz yıllarda hız kesmemiştir ve önümüzdeki yıllarda etkileri görülecektir. Sürücüsüz otomobiller, drone'lar, asistan robotlar, yapay zeka, nesnelerin interneti, artırılmış gerçeklik ile sanal gerçeklik geleceğimizde de dünyayı değiştirmeye devam edecektir. Akıllı saat ve akıllı bileklik ürünleriyle hayatımızda yer edinmeye başlayan giyilebilir teknolojilerin önemi giderek artmaktadır. Giyilebilir teknolojiler önümüzdeki yıllarda hayatımızı değiştirecek 10 teknolojik yenilikten birisi olarak sayılmaktadır. Giyilebilir teknoloji cihazlarının temel görevlerinden biri, sensörler aracılığıyla topladığı verileri doğrudan telefona ve internet üzerinden buluta aktararak sağlık, eğlence, iş ve benzeri gündelik alanlarda hayatı kolaylaştırmaktır. Bu bilgiler adım sayar, kilo ölçer, sosyal medya takibi, mesaj alıp gönderme, uzaktan konuşma, ajanda kontrolü, müzik yayını, fotoğraf çekimi gibi pek çok seçeneği kapsamaktadır. Giyilebilir teknoloji ürünleri saat ve bilekliğin yanı sıra kolye, bilezik, yüzük gibi aksesuarları da kapsıyor ve yakın dönemde akıllı lenslerin üretilmesi de gündemdedir. Giyilebilir teknolojiler alternatif tanıtım, pazarlama ve satış yöntemlerini de beraberinde getirecektir [2].

Önemli bir tekstil alanı olan teknik tekstil üretimi de dünya ticaret hacminde önemli bir yere sahiptir ve tekstil sanayii teknik tekstile doğru bir yönelim halindedir. Bugün inşaat sektöründen itfaiye elbiselerine, taşımacılıktan sağlığa kadar yaşantımızın her alanında yer alan teknik tekstil grubu, bütün tekstil uygulamaları içerisinde en hızlı büyüyen segment olarak dikkat çekmektedir. Teknik tekstil sektörü, gerek üretim sürecinde yaratılan katma değer ve gerekse de ihracat gelirleri içindeki yüksek payı nedeniyle ekonomik kalkınma sürecinde önemsenmelidir. Bu nedenle AR-GE ve altyapı yatırımlarını arttırmak, nitelikli işgücünü geliştirmek, teknoloji transferini arttırmak ve uluslararası alanda da işbirliğini arttırmak hedeflenmelidir. Türkiye'nin lokomotif sektörlerinden olan tekstil ve konfeksiyon sektörü bölgenin rekabet gücünü artıran anahtar sektörlerden biridir. Bölge için stratejik öneme sahip bu sektörde yüksek katma değerli üretime geçiş, firmaların mevcut durumda

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER

rekabet gücünün artırılması ve uluslararası alanda yeni pazarlara girmesi, üniversite-sanayi ve diğer destekleyici kurumların işbirlikleri ile mümkün olabilecektir [3].

Yukarıdaki gelişmeler ile üretilmiş en yenilikçi ürünlerden bazıları aşağıdaki gibidir [4].

- Mart 2017’de, North Face tarafından dünyanın ilk dökümlü/yumuşak yağmurluğu olan Apex Flex GTX üretilmiştir. Apex Flex, lamine naylon kullanılan geleneksel yağmurlukların aksine özel bir polyester örme kumaştan imal edilmiştir ve bu nedenle de çok daha yumuşak ve esnektir.
- Adidas, bir startup firması olan Carbon ile birlikte çalışarak, Futurecraft 4D model spor ayakkabılarını “Dijital Işık Sentezi” teknolojisi kullanarak geliştirmiştir. Dünyanın ilk yüksek performanslı spor ayakkabısı olarak tasarlanan bu modelin tek bileşenli tabanı, ihtiva ettiği 20.000 üzerinde minyatür destekler yardımıyla, belli bir fonksiyon için kontrol edilebilir enerji dönüşü sağlamaktadır.
- 2017’de dünyanın ilk “en doğa dostu” yağmurluğu OutDry Ex Eco Shell, Colombia tarafından geliştirilmiştir.
- Vollebak, 2017’de iki ürün geliştirmiştir. Bunlardan ilki, pamuk yerine %100 Kevlardan üretilen ve dolayısıyla hemen hemen her türlü dış etkiye karşı koruma sağlayan, giyim konforu yüksek sweatshirt’tür. İkinci ürün ise “güneş enerjisi ile şarj” olan yağmurluklardır. Bu yağmurlukları özel kılan ise birkaç saat içinde şarj olarak karanlıkta bir tür ışıldağa dönmesi (12 saat süreyle bu özelliğini koruyabilmekte) su geçirmemesi ve son derece hafif olmasıdır (sadece 230 g). Güneş yerine cep telefonu feneriyle (veya benzer bir fenerle) ceketini kısa süreli kullanım için şarj edebilmektedir.
- Christopher Bevans’ın lüks spor giyim markası Dyne, anoraktan taytlara kadar ilkbahar-yaz 2018 koleksiyonunun tüm parçalarını “dikişsiz” olarak üretmiştir.
- Google x Levi’s “Jakar Projesi” ile akıllı denim montları üretmişlerdir. Standart Levi’s denim montun modelinde üretilen, ancak bir akıllı telefon ile senkronize hale getirilebilen bu özel giysi, kullanıcı hareketlerine bağlı olarak tüm telefon fonksiyonlarını kontrol etmek üzere kullanılabilir.

Özellikle sanayileşmenin 4. evresini tanımlamak üzere kullanılan Endüstri 4.0, nesnelerin internete bağlanarak iletişim haline geçeceği, bu vesileyle akıllı üretimin gerçekleşeceğini ifade etmektedir. Akıllı üretim sürecine siber fiziksel sistemler, robotlar, 3d yazıcıların girmesiyle eski üretim anlayışı değişecek ve uzun yıllardır tartışılan esnek üretim devreye girecektir [5].

Giyilebilir teknolojiler ve akıllı giysiler, giysiye doğrudan dijital baskı, son teknolojik nakış makineleri, lazerli ve plazma teknolojisi ile kesim sistemleri, ultrasonik kesim sistemleri ve üç boyutlu baskı makineleri tekstil, hazır giyim ve konfeksiyon alanındaki teknolojik yeniliklerden bazılarıdır. Bu çalışmada tekstil, hazır giyim ve tekstil teknolojilerindeki son gelişmeler ve bu teknolojilerle üretilen giysiler araştırılmıştır. Tekstil, konfeksiyon ve hazır giyim sektöründeki teknolojik gelişmeleri üretimde ve ürünlerde olmak üzere 2 başlıkta inceleyebiliriz.

2. TEKNOLOJİK GELİŞMELER

2.1. Üretimdeki Teknolojik Gelişmeler

Üretimdeki teknolojik gelişmeler dijital dönüşüm ile ön plana çıkmaktadır. Endüstri 4.0 sürecine uyum sağlanması durumunda; verimlilikteki artışın % 4-7 arasında olacağı, sanayide büyümenin %3 olacağı ve istihdamda ilk on yıl içinde %5 artış olacağı tespit edilmiştir. Dünya Ekonomik Forumu’nda 2025’te dünya nüfusunun %10’unun internete bağlanabilen giyilebilir teknolojileri kullanacağı belirtilmiştir. Endüstri 4.0 ile gelen üretimin başından sonuna entegre edilen sistemler; verimlilik, atık yönetimi, üretim hızı ve kapasitesi gibi birçok konuda optimizasyon sağlamaktadır.

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER

2.1.2. Robotlar

Robotlar geleneksel olarak fabrikalardaki montaj hatlarında sıkıcı, tekrarlayan işler yapmak için ideal olmuştur. Bununla birlikte, son gelişmeler bellek ve çevikliğe sahip robotlar ile onları programlanabilir ve işbirlikçi hale getirmiştir. Bu, pozisyonların kaldırılması ile ilgili değil, daha akıllı çalışanlar yaratmak ve aynı zamanda robotların işi yapabileceği tehlikeli durumlarda onları değiştirerek insanları güvende tutmakla da ilgilidir. Örneğin, robotlarla kumaş kesmek yıllarca mümkün olmuştur, ancak robotlar bükülebilir kumaşlar veya lastikler gibi belirli tekstiller için ideal olmadığı için kesim ve dikim işlemleri zor olmuştur.

Bu konuda teknolojik çalışmalar sürmektedir. Örneğin; SoftWear Automation gibi bazı şirketler, bir robotu bir dikiş makinesinde çok doğru bir şekilde yönlendiren, maliyetleri azaltan ve süreci hızlandıran robot kollar ve vakumlu kısıkaçlarla donatılmış “Sewbots” (Şekil 2) geliştirmiştir.

Sadece iki yıl önce robotik çalışmaların başlangıcında Sewbo, kumaşı karton benzeri bir malzemeye dönüştürmek için suda çözünen sertleştirme çözümlerini kullanarak herhangi bir insan müdahalesi olmadan tişört dikebilen bir robot tasarlanmıştır.

Nike, 2013'ten beri Grabbit altında ayakkabı üretmekte olup, makinelerin nesnelere manipüle etmesine yardımcı olmak için elektro montajı kullanan bir robotik girişimdir.

Adidas Spor giyim şirketinin, SoftWear Automation'ın geliştirdiği, Sewbot adını verdiği robotu kullanarak günde 800 bin tişört üretebileceği belirtilmektedir. Tek bir insan rehberliğinde çalışan robotun, 1 saatte 17 insan kadar tişört yapabileceği ve her 22 saniyede bir tişört üretebilecek güce sahip olabileceği ve bu sayede, üretimdeki artışın % 300'e ulaşacağı belirtilmektedir. Bitmiş ürün görmek için kumaşların kesim ve dikiş süresi toplam dört dakika olacaktır [6].



Şekil 2: Robot uygulaması (Sewbot)

2.1.3. Üç Boyutlu Yazıcılar

3D baskı veya eklemeli üretim, dijital bir dosyadan üç boyutlu katı cisimler yapma işlemidir. 3B basılı bir nesnenin yaratılması, ilave işlemler kullanılarak elde edilir. İlave bir işlemde, nesne yaratılana kadar ardışık malzeme katmanlarını bırakarak bir nesne yaratılır. Bu katmanların her biri, nihai nesnenin ince dilimlenmiş yatay bir kesiti olarak görülebilir. 3D baskı, örneğin bir freze makinesinde bir metal veya plastik parçasını kesen / oyup çıkartan üretimin tam tersidir. 3B baskı, geleneksel üretim yöntemlerinden daha az malzeme kullanarak karmaşık (işlevsel) şekiller üretilmesini sağlar.

Literatürde üretim yöntemlerine, kullanılan hammaddeye göre farklı sınıflandırmalar yapılsa da, temel olarak moda ve tekstil tasarımında bu yazıcıların kullanımı iki amaçla/şekilde olmaktadır. İlk olarak giysi bütün olarak bu yöntemle üretilmekte (Şekil 3, Şekil 4), ikinci olarak da tekstil yüzeyinde temel teşkil eden dokuma veya örme ile oluşturulmuş yüzeylere alternatif olabilecek, farklı bağlantı şekilleriyle bilinen dokuma ve örme kumaşlara alternatif yüzeyler (Şekil 5) elde edilebilmektedir [11]. Şekil 3'de üç boyutlu yazıcılarla üretilmiş ve farklı defilelerde sergilenmiş bütün giysi modelleri görülmektedir.

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER



Şekil 3: Sol: İlkbahar / Yaz 2014 Koleksiyonu (New York Moda Haftası); Merkez: Sonbahar / Kış 2016 Koleksiyonu (New York Moda Haftası); Sağ: İlkbahar / Yaz 2017 Koleksiyonu (New York Moda Haftası) [12].

Üç boyutlu yazıcılar, moda ve tekstil tasarımında, giysi üretimi ve tekstil yüzeyinde dokuma ya da örme ile oluşturulmuş yüzeylere alternatif olabilecek, farklı işleme modelleriyle ürünler elde etmek için kullanılabilir.

3D baskının moda sektöründe de giderek artan şekilde kullanıldığını görebiliriz. 3D baskılı haute couture'un öncüsü sayılan Iris Van Herpen, Materialize ile işbirliği yaparak elbiseler basmaktadır (Şekil 4).




Şekil 4: Hollandalı tasarımcı Iris Van Herpen tarafından tasarlanan İlkbahar / Yaz 2012 Haute Couture koleksiyonunda 23 Ocak 2012'de Paris'te sergilenen eserler [13].

Geleneksel olarak üç boyutlu baskı ile bir araya getirilen modeller katı bir davranış sergilemektedir, ancak yeni projeler nesnelere şekline ve hareketine uyum sağlayan esnek yapılar yaratmayı amaçlamaktadır. Sonuçlar, gevşek zincir benzeri yapılar veya katı tekstil görünümlü yapılar [14]. Son zamanlarda yapılan bir araştırma, bir lazer sinterleme (SLS -Selective Laser Sintering) ile üç boyutlu yazıcıda esnek atkı örme yapılar oluşturmanın mümkün olduğunu bildirmiştir

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER

[15]. Shankar College mezuniyet defilesinde sunduğu, FDM (Fused Deposition Modelling) tipi üç boyutlu yazıcılarla poliamid kullanarak yaptığı giysilerde esnek yüzeyler elde etmeyi başarmıştır [16]. Şekil 5'te dokuma ve örme yüzeylere alternatif olarak tasarlanmış yüzey örnekleri ve dijital ortamda tasarım çalışmaları görülmektedir.



Şekil 5. Dokuma veya örme ile oluşturulmuş yüzeylere alternatif üç boyutlu yapı örnekleri [17].


Üç boyutlu yazıcılar için kullanılan hammaddeler metal, seramik tozu, fotopolimer sentetik maddeler, termoplastik sentetik polimerler, PLA (Polilaktik Asit), ABS (Akrilonitril Butadin Stiren) ve son zamanlarda da naylondur. Bu tür yazıcılar, termoplastik polimerleri, bir düze boyunca baskı yerine eriterek ve ekstrüzyon yaparak dizeler halinde işler. Endüstriyel yazıcılarda, termoset işlemine uygun malzemelerin yanı sıra metal, seramik veya fosil reçineleri kullanmak da mümkündür.

Adidas Futurecraft 4D ve 3D baskılı tabana sahiptir. Adidas, DLS (Direct Laser Sintering), 3D baskı işlemlerini kullanmak için Carbon ile düzenlemeler yapmıştır. Bu olanaklara ilgi duyan büyük şirketler kaçınılmaz bir büyüme dalgasının göstergesidir.

2.1.4. Makinalardaki Teknolojik Öğrenme

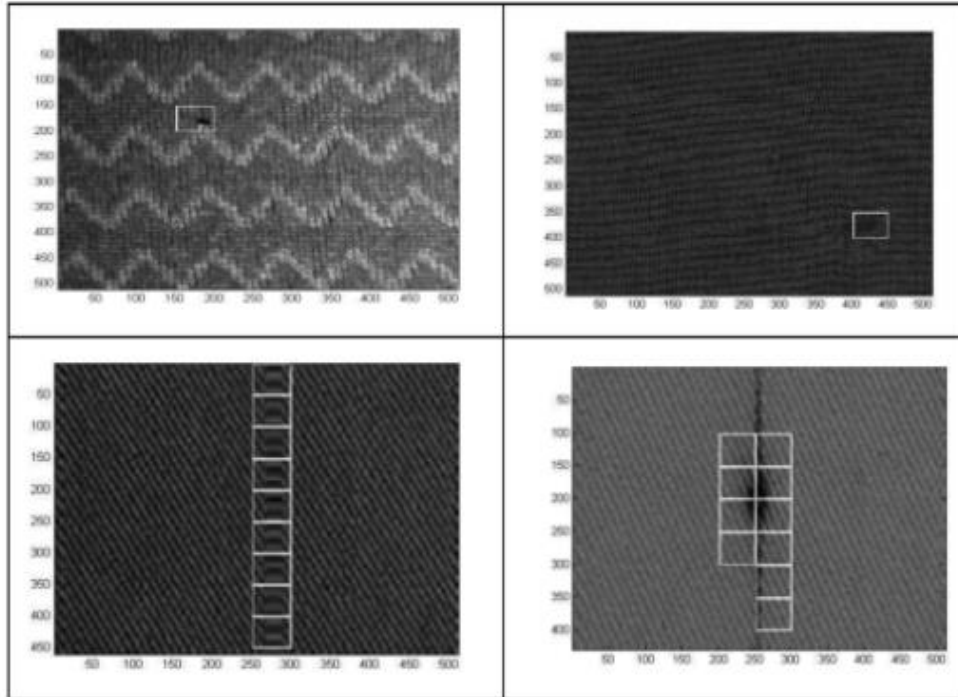
Bir makinenin akıllı insan davranışını öğrenme ve benimseme yeteneği yeni değildir. Günümüzde, bu gelişmiş algoritmalar imalat sanayinin bilgi toplama, vasıflı işgücü gerçekleştirme ve tüketici davranışını öngörme şeklini değiştiriyor. Hatta bazıları trend modelleri, silüetler, renkler ve stillerde temaları tahmin eder ve ürünler ve pist görüntüleri etrafında müşteri duyarlılığı sağlar. Bazıları bir markanın ideal müşterisi için doğru zaman ve ürünün ne zaman olduğunu tespit etmek için insanların yerini alabilmektedir. Yapay Zeka, Yapay Sinir Ağları, Görüntü İşleme Teknikleri ve Algoritmalarla öğrenen makinalar bir çok konuda tahminleme yaparak kararlar almakta ve kumaş kalite kontrolü, renk eşleştirme gibi çalışanların vermek zorunda oldukları kritik kararlarda önemli görevleri üstlenmektedir. Şekil 6'da bir makine öğrenmesi ile elde edilmiş baskılı bir elbise örneği görülmektedir. Bu renkli elbise kolayca en yeni makine öğrenme teknolojisi tarafından yaratılmış bir yapay zeka ürünü elbisedir. Elbisedeki baskı, LIGO (The Laser Interferometer Gravitational -Wave Observatory) yerçekimi dalga dedektöründen üretilen veri analizini hızlandırmayı öğrenmenin bir sonucudur.

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER



Şekil 6: Yapay zeka ile üretilmiş bir baskı deseni ve elbise örneği [18].

Şekil 7’de kumaş kalite kontrolünün görüntü işleme teknikleri ile tespiti görülmektedir. Kumaş üretiminin son noktası olan kalite kontrol aşamasında, operatör kalite kontrol aşamasında her hatayı manuel olarak işaretler ve tanımlama sonuçlarını bilgisayara girer. Görüntü işleme teknikleri sayesinde bilgisayar, işaretleme, tanımlama, kayıt ve raporlama sistemini yapabilmekte, hataları algılayabilmekte, hatanın türünü tanımlayabilmekte, konumlarını bir aygıtla işaretleyebilmekte ve rapor edebilmektedir.



Şekil 7: Görüntü işleme tekniği ile kumaş kalitesinin tespit edilmesi [19].

Örneğin Tommy Hilfiger, kısa süre önce, üretimi, satışları optimize etmek ve ayrıca maliyeti ve israfı azaltmak için bu tür verileri belirlemek üzere bir Yapay Zeka Sistemi geliştirmek üzere IBM ve Fashion Institute of Technology ile bir ortaklık yaptığını açıklamıştır. FIT'deki öğrenciler, gerçek zamanlı moda endüstrisi trendleri, şirketin yeni ürün geliştirme için bilinçli kararlar almak üzere geri gönderdiği her Tommy Hilfiger çevresinde müşteri duyarlılığı gibi şirketin verilerine bakmak için bilgisayar vizyonu dahil olmak üzere IBM Research'in Yapay Zeka yeteneklerine sahip olacaktır.

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER

San Francisco merkezli, Stitch Fix gibi başka bir şirket de müşterilere çevrimiçi stilistler yardımı ile kıyafet temin ediyor, Yapay Zeka ile çalışıyor. Şimdi Stitch Fix envanterinde eksik olan trendleri ve stilleri tanımlayan algoritmalar tarafından oluşturulan giysileri tasarlıyorlar. Bunlar, tüketicilerin Yapay Zeka sistemi tarafından seçilen ve daha sonra yeni bir tasarım öneren favori renk, desen ve tekstil seçimlerinin kombinasyonuna dayanır. Daha sonra bu yeni tasarımlar bir (insan) tasarım ekibi tarafından gözden geçirilir.

Yapay Zeka'yı hazır giyim sektöründe kullanmanın ilginç bir örneği, Google ve Zalando tarafından geliştirilen bir proje olan "Project Muze"dir. Proje, Google'ın Moda Trendleri Raporundan elde edilen renkleri, dokuları, stil tercihlerini ve diğer estetik parametreleri ve ayrıca Zalando tarafından sağlanan tasarım ve trend verilerini anlamak için sinir ağını eğitti. Proje, kullanıcıların ilgi alanlarına göre, ağ tarafından tanınan stil tercihlerine göre tasarımlar oluşturmak için bir algoritma kullandı. Sonuçta, Muze Projesi ile yaratılan moda parçaları tamamen başarılı değildi, ancak hazır giyim endüstrisinde Yapay Zeka kullanma olasılıkları hala gelişme aşamasındadır ve umut verici ilerleme göstermektedir. Ürün geliştirme teknolojisinin sağlayabileceği örneklerden bazıları arasında dijital showrooamlar ve sanal tasarım yer almaktadır [20].

Yeni üretim teknolojileri, hazır giyim endüstrisinin emek yoğun üretimden sermaye yoğun üretime geçmesini sağlamaktadır. Yeni üretim teknolojisinin diğer sonuçları arasında daha hızlı üretim, daha az atık, yeniden pazarlama ve pazara yakın üretimin yerleştirilmesi ve daha düşük karbon ayak izleri sayılabilmektedir. Yeni üretim teknolojisi çözümleri şunları içermektedir:

- Lazerle kesme makineleri, eritme makineleri, düğme deliği makineleri ve dikiş yapıştırma makineleri gibi dikiş makinelerinde yenilikler;
- Dikiş robotları;
- Dikişsiz giysiler;
- Şirketlere ve tüketicilere, belirli tüketicilerin tasarımlarını ve fikirlerini hızlı ve nispeten ucuz bir şekilde özelleştirebilme ve üretebilme yeteneği sağlayan dijital tekstil baskısı.

2.1.5. Blok Zincir (Blockchain) Teknolojisi

Blockchain teknolojisi, ürünler ve bir blockchain üzerindeki dijital kimlikleri arasında fiziksel-dijital bir bağlantı oluşturma özelliğine sahiptir. Bu tür bir bağlantı daha şeffaf bir tedarik zinciri için fırsatlar açar. Blockchain ile her bir ürün için zaman damgalı dijital bir bilgi geçmişi veya toplam değer zincirinin denetim zincirini oluşturabilirsiniz. Bu veriler değişmez olduğu için tek taraflı olarak değiştirilemediği için blockchain, şirketlerin ürünleri ve süreçleri hakkında sağladıkları bilgileri doğrulamak için ekstra bir güvenlik katmanı yerleştirir.

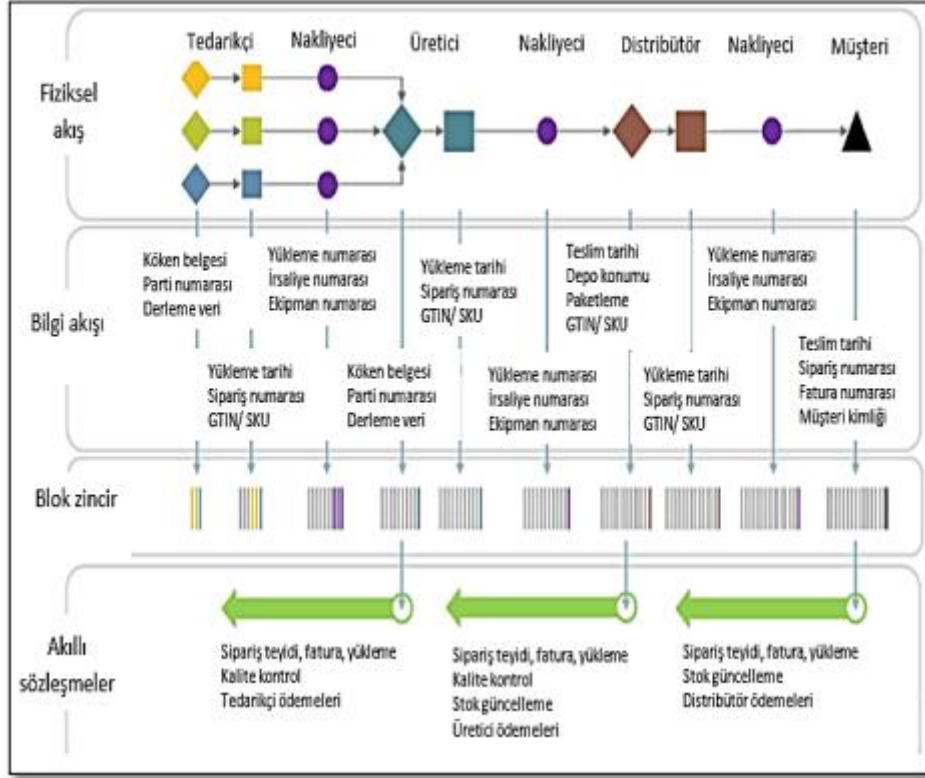
Blockchain teknolojisinin kullanımı hazır giyim endüstrisini değiştirmiş ve tedarik zincirinde şeffaflığı uygulamak için yeni yollar sunmaktadır. Blockchain kullanarak, bir ürüne eklenen bir çip veya bir etiket, aşağıdakiler dahil olmak üzere, o ürünle ilgili tüm ilgili verileri depolamak için kullanılabilir:

- pamuğun sağlandığı çiftlik;
- ipliği kim yaptı;
- boyamak için kullanılan şey;
- ürünü kim üretti;
- nasıl sevk edildiğini;
- her adımda geçmişteki maliyetler;

Tüm bu "blokklar" verileri bu ürünün etiketinde depolanabilir ve daha sonra bu zincire katılan herhangi bir sayıda bilgisayar kullanıcısı tarafından erişilebilir ve doğrulanabilir.

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER

Örneğin, kullanım sırasında veritabanına belirli bir materyalin kaynağı eklendiğinde, bu veriler o anda blockchain teknolojisi ile güvence altına alınır. Veriler daha sonra örneğin hızlı yanıt (QR) kodları kullanılarak cips, etiketler ve tarama kullanılarak saklanabilir ve okunabilir. Ürünün ömrünün ilerleyen saatlerinde, üretim, dağıtım, satış ve hatta elden çıkarılması sırasında, hiç kimse bilgileri kurcalandığını görünür yapmadan değiştiremez. Şekil 8’de blok zincirinin nasıl kullanıldığı gösterilmektedir.



Şekil 8: Blok zincirinin kullanımı [21].

Hazır giyim sektöründe blok zincir teknolojisinin gelecekteki uygulamaları aşağıdaki şekildedir:

- sahte ürünlerin satışının önlenmesi;
- örneğin organik pamuktan alınan sertifikaların ‘çift harcamasını’ önlemek;
- akreditiflerin değiştirilmesi;
- küçük işletmeler için alternatif finansman ve ödeme yöntemleri sunabilecek kripto para birimlerinin kullanılması;
- anında izlenebilirlik, gelişmiş envanter yönetimi ve otomatik geri dönüşüm için giysiler ve envanterdeki radyo frekansı tanımlama (RFID) etiketleri.

2.2. Ürünlerdeki Teknolojik Gelişmeler

Ürünlerdeki teknolojik gelişmeler ise 2.1 maddesinde yer alan teknolojiler ve konvansiyonel sistemler ve nanoteknoloji kullanılarak çok akıllı, pasif ve aktif akıllı malzemelerden elde edilen akıllı giysiler, nanoteknoloji ile üretilmiş teknolojik kumaşlar ve inovatif ürünlerdir.

2.2.1. Giyilebilir Teknolojiler

Giyilebilir teknoloji ürünleri aksesuar veya giysiler üzerinde bilgi ve iletişim teknolojilerinin kullanılmasına yönelik tekstiller ile birleştirilmesi ile gündeme gelmiştir. Giyilebilir sistemlerin geliştirilmesinde, bir giysi veya kumaşa bilgi ve iletişim teknolojilerinin entegre edilmesi en önemli

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER

hedeflerden birini oluşturmaktadır. Çevre değişkenlerini algılama teknolojisi, insan ve bilgisayar arasında bir ara yüzey oluşturmaktadır. Elektronik tekstiller, kumaşlara anti-statik madde emdirilmesi, kumaşların ve dokusuz yüzeylerin iletken malzemelerle kaplanması ve iletken ipliklerin iletken olmayan ipliklerle katlanmalarıyla elde edilirler.

“Akıllı Saatler (Smartwatches)”, “Akıllı Bileklikler”, “Akıllı Gözlükler ve Görsel Bazlı Giyilebilirler”, “Akıllı Kulaklıklar”, “Sanal Gerçeklik (VR) Gözlükleri”, “Akıllı Tekstil Ürünleri” ve “Akıllı Aksesuar & Mücevher” giyilebilir teknolojilerden bazılarıdır. Şekil 9’da giyilebilir teknoloji ürünleri yer almaktadır.



Şekil 9: Giyilebilir Teknoloji Ürünleri

Akıllı giysiler giyilebilir teknolojilerde önemli bir yer tutmaktadır. Bu konuda bir çok ticari firma ürünler geliştirip piyasaya sürmektedir. Örneğin Tommy Hilfiger’in ürettiği (Şekil 10) güneş enerjisi ile şarj edilen ceketin arkasında güneş panelleri vardır ve ön kısımlarındaki ceplerde güneş enerjisinin elektrik enerjisine dönüştürülmesi ile USB bağlantı noktası üzerinden telefonları şarj edebilmektedir.




Şekil 10: Tommy Hilfiger’in Ürettiği Güneş Enerjisi ile Şarj Edilen Ceket [6].

Yakın gelecekte dünya nüfusunun %10’u internete bağlanabilen giyilebilir teknolojiler kullanacağı belirtiliyor. Giyilebilir teknolojinin önemli özelliklerinden biri, internete bağlanarak cihaz ile ağ arasında veri aktarımı yapabilmesidir. Bu veri alışverişi sayesinde giyilebilir teknoloji, nesnelerin interneti dünyasında ön plana çıkmaktadır. Bu teknoloji ile; bir atletin (koşucu) koşu esnasında vücut sıcaklığı, futbolcunun topa vurma hızı, bir bebeğin anne karnında kalp atış hızı, kola takılan basit cihazlar ile anlık kan basımı ölçümü gibi bilgilere ulaşılabilir. Bu cihazlar futbol

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER

topunun içine, ayakkabının sert bir taban kısmına, bilek, kol hatta deri altına dahi yerleştirilebilmektedir [6].

Dijital giyim şirketi Cute Circuit'in ürettiği dijital tişört "TshirtOS" giyilebilir teknoloji ürünüdür (Şekil 10). Bir dizi uygulama ve araçla birlikte bir LED ekrandan oluşan tişört, tweet gönderme, müzik çalma ve müzik alışverişi yapma, fotoğraf çekme, paylaşma ve yükleme ve daha pek çok şey gibi platformu kontrol etmek için telefona bağlı olarak kontrol edilebilmektedir.



Şekil 10: Dijital giyim şirketi Cute Circuit'in ürettiği dijital tişört "TshirtOS".

Giyilebilir teknolojilerin geliştirilmesinde en önemli amaç giysi veya kumaşa bilgi ve iletişim teknolojilerinin entegre edilmesi olmuştur. Akıllı tekstiller içerisinde yer alan akıllı giysiler, bilgisayar klavyesi, cep telefonları, mikrofonlar, mp3 çalarlar, video kameralar gibi elektronik parçaların giysilere entegre edilmesi sonucu ortaya çıkmaktadır. Bu giysilerin kullanım alanı bulunduğu alanlardan biri de sağlık sektörüdür. Sağlık, tekstil sektöründe önemli bir pazar olarak değerlendirilmektedir. Elektronik tıp alanındaki tıbbi tekstiller, elbiseye entegre edilen sensörler ve iletişim sistemleri aracılığıyla hastanın tıbbi göstergelerinin elde edilmesi, izlenmesi ve bunların doktora, hastaneye veya acil servise bildirilmesine olanak vermektedir. Pek çok ülkenin tekstil mühendisleri, polimer kimyacıları, fizikçiler ve biyo mühendisleri geleceğin tekstilleri ve giysileri üzerine düşünmekte ve bu düşünceleri gerçeğe dönüştürecek yeni teknolojiler geliştirmek üzere çalışmaktadırlar [21].

Sağlık alanında, (Şekil 11) etkinlik izleme cihazları, kalp pilleri ve işitme cihazları üretmek için giyilebilir teknoloji kullanılmaktadır. Ayrıca, kalp atış hızı, yakılan kaloriler, tansiyon ve şeker içeriği gibi önemli olayların etkin bir şekilde araştırılmasını sağlayan araçlar, giyilebilir uygulama üreticileri tarafından geliştirilmektedir.



Şekil 11: Sağlık Alanında Giyilebilir Teknolojilerin Kullanımı

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER

Mevcut giyilebilir teknoloji cihazlarına örnekler aşağıdaki şekildedir :

- Fitbit, Runtastic, Mio, Misfit, Nike, Microsoft ve Garmin gibi spor takip bantları;
- Akıllı spor sütyenleri;
- Apple Watch ve Wear OS'de çalışanlar dahil akıllı saatler;
- Google Glass ve Sony'nin SmartEyeGlass gibi akıllı gözlükleri;
- Evcil hayvanlar için giyilebilirler;
- Dahili LED'li ceketler gibi dış giyim.

Giyilebilir teknolojilerde kullanılan teknoloji örnekleri aşağıdaki şekildedir :

- Radyo Frekans Tanımlama (RFID) - Dijital bir soyunma odasında, sensörler, akıllı bir aynaya bağlanırken, müşterinin üzerinde çalıştığı giyim ürünlerinde RFID etiketlerini veya ipuçlarını okuyabilir. Tüketici daha sonra seçeneklere göz atabilir, farklı boyutlarda talep edebilir ve hatta soyunma odasının içinden eşleşen öğeleri sipariş edebilir. Bu, tüketicinin doğru boyutu almasını ve iyi bilgilendirilmiş alımlar yapmasını sağlar;
- Şarj edilebilir piller ve dahili güneş pilleri taşınabilir aygıtlar için giyilebilirler için taşınabilir bir güç kaynağı yapabilir;
- Yakın Alan İletişimi Teknolojisi - Bu giyilebilir teknoloji, tüketicilerin kıyafetleriyle etkileşimde bulunmalarını ve kullanılan malzemeler, maliyet ve üretici dahil giysi hakkında bilgi almalarını sağlar. Bir Yakın Alan İletişimi (Near Field Communication-NFC) yongası, her giysiyi istenen herhangi bir bilgi ile kişiselleştirebilir;
- Bluetooth Low Energy, önceki Bluetooth teknolojisine göre çok daha az pil gücü kullanırken giyilebilir cihazların akıllı telefonlarla iletişim kurmasını sağlar.

2.2.2. Nano Teknoloji ile Üretilmiş Ürünler


Yunanca "cüce" anlamına gelen nano herhangi bir ölçünün milyarda birini göstermektedir. İnsan saç teli çapının yaklaşık 100.000 nanometredir. Normal tekstil liflerinin çapı 10000 nm ya da daha geniştir. Nanolifler ise, çapı 1 mm ya da 1000 nm den daha küçük olan lifler olarak tanımlanır.

Çok küçük maddelerin teknolojisi olarak nano teknoloji tekstilde de başarı ile uygulanmaktadır. Nano-teknolojinin tekstil endüstrisindeki günümüzdeki uygulamalar lif, iplik, kuma, dokusuz yüzey, boyama ve kaplama gibi terbiye işlemleri, elektronik tekstiller, elyaf modifikasyonu ve katma değerli ürünlerdir.

Düşük kimyasal kullanım; düşük enerji maliyetleri; tutum, mukavemet, hava geçirgenliği, ıslanma gibi fiziksel ve mekanik özellik kaybının az olmasından dolayı nano-teknoloji tekstil ve giysi uygulamalarında kullanılmaktadır. Buruşmazlık, anti statiklik, su geçirmezlik, leke tutmazlık, ultraviyole koruyuculuk, antimikrobiyalite, daha iyi boyanabilirlik, yanmazlık veya güç tutuşurluk özellikleri nano teknoloji uygulamaları ile yapılmaktadır.

Nanoteknolojinin tekstilde en iyi bilinen ticari uygulama alanı nanopartikülleri kullanarak kumaş ve giysilere sıvı itici, yağ ve leke dayanımı etkisi kazandırmak için yüzey işlemi uygulanan tekstil endüstrisidir. Bu lotus (Nilüfer çiçeği) yaprağı efekti olarak bilinmektedir. Şekil 12'de kumaş yüzeyine uygulanan nilüfer çiçeği efekti görülmektedir.

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER




Şekil 12: Nilüfer Çiçeği Efektinin Tekstil Mamüllerine Uygulanışı

Işık, basınç, kimyasal gibi çeşitli dış etkilerdeki değişmelerle renk değiştiren ürünler (Şekil 13), nabız, sıcaklık, tansiyon gibi vücut fonksiyonlarındaki değişmeleri belirleyip kullanıcıyı uyararak giysiler, bilgisayar, yol bilgisayarı, müzik çalar, cep telefonu, internet bağlantı elemanı gibi işlevlere sahip olan, vücut işlevlerimizi kontrol edebilen, gerektiğinde ilaç veren tekstil ürünleri (Şekil 14) ve giysiler nano teknoloji ile üretilebilmektedir.




Şekil 13: Işık, Basınç, Kimyasal Gibi Çeşitli Dış Etkilerdeki Değişmelerle Renk Değiştiren Ürünler




Şekil 14: Gerektiğinde İlaç veren İlaç Yüklü PCL Nanolifleri

TEKSTİL VE KONFEKSİYON SEKTÖRÜNDEKİ TEKNOLOJİK GELİŞMELER

Ayrıca aloe veralı çarşaf, böceksavar gömlekler, masaj yapan ayakkabılar, selülit kremi yerine geçen çoraplar, baş ağrısı için ağrı kesici görevi gören bereler, ter kokusunu önleyen ve etrafa parfüm kokusu yayan gömlekler, çoraplar, bu teknoloji ile üretilmekte ve yenilikçi tekstil ürünleri olarak değerlendirilmektedir. Ayrıca sağlık alanında kullanılan yara bandları, nanolifli yapı içinde kemik ve kök hücrelerinin geliştirilmesi de diğer uygulama alanlarındandır (Şekil 15, 16).



Şekil 15: Nanolifli Yapı İçinde Gelişen Kemik Hücreleri



Şekil 16: PES Elektropsun Nanolifli Yapı Üzerinde Geliştirilen Hematopoez Kök Hücreleri

3. SONUÇLAR

2005 yılından itibaren Türk tekstil ve hazır giyim sektörleri rekabet alanını değiştirmiş, geleneksel ve basit ürünlerle rekabet etmek yerine, yüksek katma değerli tekstil ürünleriyle ve hazır giyimde markalaşma yolunda daha güçlü bir yapıya dönüşme çabası içerisine girmiştir. 2023 yılında dünya tekstil ticaretinin 550 milyar dolara, hazır giyim ticaretinin ise 740 milyar dolara ulaşacağı öngörülmektedir. Ülkemizin 2023 yılı için 500 milyar dolarlık ihracat hedefine ulaşabilmesi için ihracatçı birlikleri tarafından hazır giyimde 52 milyar dolar, hazır giyim dahil tekstil sektörü için toplam 100 milyar dolar ihracat hedefi belirlenmiştir. Bununla birlikte dünya tekstil ve hazır giyim ticareti içindeki %3,6'lık payımızı korumak için 2023'te en az 26 milyar doları hazır giyimde olmak üzere tekstil ve hazır giyimde toplam yaklaşık 50 milyar dolar ihracat hedefine ulaşmamız şarttır. Sektörlerin 2023 hedeflerini en iyi şekilde gerçekleştirebilmeleri için mevcut avantajlarının yanında Dokuzuncu Kalkınma Planı çerçevesinde hedeflenen “tedarikçi ülkeden piyasa yapıcı ülkeye dönüşüm” ve “bilgi bazlı ürünlerin üretimine yönelme” yolunda kamu-özel sektör işbirliği ile çalışmalar hızla yürütülmelidir [22].

Tekstil ürünlerinde teknik özelliklerin ön plana çıkması ve teknolojik özelliklerin daha da geliştirilmesi ile yaratılacak olan tekstil ürünleri önümüzdeki yıllarda daha da yaygınlaşacaktır.

Böylece teknik tekstil materyalleri, malzeme bilimi, tekstil teknolojisi ve elektronik bilimi alanlarını kapsayan disiplinler arası çalışmalar daha da artacaktır.

Bu çalışmalar tekstil sektörü ile bilişim sektörünü bir araya getirmeyi ve üretimde teknolojiyi kullanmayı hedefleyen Endüstri 4.0 ile giyilebilir teknolojiye sahip ürünleri moda için daha da önemli bir noktaya getirecektir.

Gelecekte, giyilebilir teknoloji ile fonksiyonel moda ürünleri tasarlayacak, ileri teknoloji içeren malzemeleri giysilerde kullanacak vizyon sahibi tekstil ve moda tasarımcıları gündemde olacaklardır.

4. KAYNAKÇA

- [1] <http://www.worldmarch.org/clothing-industry.html>
- [2] <http://www.hurriyet.com.tr/teknoloji/2017de-dunyayi-degistirecek-10-teknoloji-trendi-40334937>
- [3] www.butekom.org
- [4] <http://www.tekstilteknik.com.tr/gelecegi-sekillendirecek-yenilikler-mi/>
- [5] Özsoylu, A.F., 2017, Endüstri 4.0, Çukurova Üniversitesi İİBF Dergisi, 21(1),41-64.
- [6] <http://www.sanayinindijitaldonusumu.com/tekstil-sektorunde-dijital-donusum-ve-yeni-nesil-urunler/>
- [7] Çakır, F. S., Aytekin, A., Tüminçin, F., Nesnelerin İnterneti ve Giyilebilir Teknolojiler, Sosyal Araştırmalar ve Davranış Bilimleri Dergisi, 2018, Cilt 4, Sayı 5, s. 84-95.
- [8] Köroğlu, O. (2015). Nesnelerin İnterneti, Algılayıcı Ağları ve Medya. İçinde Akademik Bilişim Konferansı. Eskişehir.
- [9] Aktaş, F., Çeken, C., & Erdemli, Y. E. (2016). Nesnelerin İnterneti Teknolojisinin Biyomedikal Alanındaki Uygulamaları. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 4(1).
- [10] <https://www.monnit.com/internet-of-things>.
- [11] Yıldırım, M., Moda Giyim Sektöründe Üç Boyutlu Yazıcılarla Tasarım ve Üretim, 2017, Süleyman Demirel Üniversitesi Güzel Sanatlar Fakültesi Hakemli Dergisi ART-E Mayıs-Haziran'16 Sayı:17, ISSN 1308-2698.
- [12] <https://www.bluedge.com/blog/miscellaneous/12-fashion-designers-whove-embraced-3d-printing>.
- [13] <https://www.theguardian.com/technology/2013/oct/15/3d-printed-fashion-couture-catwalk>.
- [14] Melnikova, R. & Ehrmann A. & Finsterbusch K.: 3D Printing of Textile-based Structures by Fused Deposition Modelling (FDM) with Different Polymer Materials, (2014) Global Conference on Polymer and Composite Materials (PCM 2014) IOP Publishing IOP Conf. Series: Materials Science and Engineering 62 (2014) 012018 doi:10.1088/1757-899X/62/1/012018 .
- [15] Timmermans, M., Grevinga, Th.; Brinks, G. J.: Towards 3D Printed Textiles, Proceedings of 15th Autex World Textile Conference, Bucharest Romania, June 2015
- [16] Mariott, H., (2015), Are We Ready to 3D Print Our Own Clothes?, <http://www.theguardian.com/fashion/2015/jul/28/are-we-ready-to-print-our-own-3dclothes> (Erişim tarihi: 21.04.2019).
- [17] <https://inhabitat.com/ecouterre/are-3d-printed-fabrics-the-future-of-sustainable-textiles/>.
- [18] <https://shenovafashion.com/products/artificial-intelligence-dress>.
- [19] <https://medium.com/deep-learning-turkiye/teksti%CC%87lde-yapay-zeka-kullanimi-7f97f23c571d>.
- [20] <https://www.cbi.eu/market-information/apparel/how-apply-new-technologies-apparel>.
- [21] Bakan, İ. Şekeli, Z., 2019, Blok Zincir Teknolojisi ve Tedarik Zinciri Yönetimindeki Uygulamaları, Uluslararası Toplum Araştırmaları Dergisi, 11(18), DOI: 10.26466/opus.563240.
- [22] <http://www.konfeksiyonteknik.com.tr/hazir-giyim-sektorundeki-gelismeler/>

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

Sümeyye Çelik

Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Yönetim Bilişim Sistemleri Bölümü, Adana, Türkiye

sumeyyecelik@atu.edu.tr

1. GİRİŞ

Günümüzde gelişen teknoloji ve azalan depolama maliyetleri kaydedilen veri miktarlarında çok yüksek bir artışa sebep olmaktadır. Bu artış ise devamında yığın halde depolanmış verileri ortaya çıkarmaktadır. Durum böyle olunca yığın halde duran verileri, amaçlar doğrultusunda kullanma ihtiyacını ortaya çıkmaktadır. Böylece önceki dönem verileri arasında ilişkiler kullanılarak pozitif fayda sağlamaktadır. Var olan ve öngörü aracı olarak kullanılmak istenen veriler olunca, veri madenciliği gibi yeni yaklaşımlar geliştirilmiştir. Veri madenciliğinin tanımına bakıldığı zaman var olan veriler arasındaki anlamlı olan bilgileri ortaya çıkarmak amacı doğrultusunda gerçekleştirilen tüm işlemlerin genel adı olduğu görülmektedir. Bu sebepten dolayı veri madenciliği ana başlığının altında birçok alt başlık ve çalışma biçimi yer almaktadır. Sınıflandırma, kümeleme ve birliktelik kuralları başlıca veri madenciliği yöntemleri arasında sayılmaktadır.

Kümeleme yapmak temelde benzer olanları bir araya getirerek farklı olanları ayırma işlemidir. Kümeleme yapmak için geliştirilmiş birçok yaklaşım olmakla birlikte temelinde bir grup veri içinde birbirine yakın olanların belirlenmesi amacı güdülmektedir. Kümeleme yöntemleri veri madenciliği yöntemleri arasında oldukça popülerdir ve literatürde de çokça kullanılmaktadır. Geçmişten günümüze kadar kümeleme yapmak için birçok yöntem geliştirilmiş ve halen de geliştirilmeye devam etmektedir. K-means en eski kümeleme yöntemlerinden bir tanesidir ve çalışma yapısı oldukça basittir ama k parametresi olarak ifade edilen küme sayısını kullanıcı tarafından girilmesi gerekliliği en büyük eksikliği olarak görülmektedir. Bu eksikliği gidermek amacıyla literatürde birçok yöntem geliştirilmiş olmakla birlikte x-means onlardan bir tanesidir. X-means 2000 yılında ortaya konulmuştur ve güncel yöntemler arasında sayılmaktadır. Çalışma yapısı olarak k-means yöntemini kullanmakla birlikte k-means yöntemine ek olarak k parametresi için tek değer girilmesi zorunluluğunu ortadan kaldırmak için k parametresinin içinden seçileceği bir aralık verilmesi fikrine dayalı olarak çalışmaktadır. Böylece küme sayısı belirlenirken birden fazla ihtimalin değerlendirilebilme imkan tanınmaktadır. Bu çalışmada da k-means ve x-means ile kümeleme yapılmış ve sonuçlar değerlendirilerek performanslar karşılaştırılmıştır.

Çalışmada kullanılan veri seti 2009-2013 yılları arasında Portekiz'in Coimbra şehrinde bulunan Coimbra Hastanesi ve Üniversite Merkezi, Kadın Hastalıkları Bölümüne başvuran toplamda 166 bireyden alınan bilgiler ile oluşturulmuştur. Her bireyin Age (years), BMI, Glucose (mg/dL), Insulin (μ U/mL), HOMA, Leptin (ng/mL), Adiponectin (μ g/mL), Resistin (ng/mL), MCP-1(pg/dL) değerleri öznitelik olarak kullanılmıştır. Bu değerlerin karşılığında ise bireylerin meme kanseri tanısı yer almaktadır. Veri seti UCI machine learning repository sitesinden temin edilmiştir ve veri setinin ismi Breast Cancer Coimbra Data Set'tir (<https://archive.ics.uci.edu/ml/index.php>, 15.03.2019).

2. VERİ MADENCİLİĞİ

Veri madenciliği mevcut olan fakat işlenmediği zaman bir anlam ifade etmeyen, karmaşık ve yığın halinde bulunan verilerin bir sistematik içerisinde işlenerek anlamlandırılma sürecidir (Delen vd., 2005). Bu süreç sonunda veriler arasında bulunan örüntüler elde edilmektedir (Albayrak ve Koltan Yılmaz, 2009). Elde edilen örüntüler sayesinde anlamlandırılan veriler bilgi olarak karşımıza

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

çıkılmaktadır (Guo vd., 2009). Böylece ortaya çıkarılan örüntüler sayesinde elde edilen bilgiler aracılığı ile daha hızlı ve daha doğru kararların alınmasına olanak tanınmaktadır. (Hong ve Wu, 2011). Veri madenciliği ana başlığının altında sınıflandırma, kümeleme, birliktelik analizleri gibi birçok alt başlık mevcuttur ve sürekli olarak geliştirilerek yeni teknikler ortaya konulmaktadır (Wei ve Chiu, 2002). Bu açıdan bakıldığında zaman veri madenciliği teknikleri çok geniş bir kullanım alanına sahiptir (Koyuncu ve Özgülbaş, 2009). Çok fazla teknik olması yapılan işlemlerin tek başlık altında toplanmasını zorlaştırmakla birlikte tüm yöntemlerde ortak olarak izlenen ortak süreç şu şekildedir;

Öncelikle problem tanımlanmaktadır. Daha sonra toplanacak ve üzerinde işlemler gerçekleştirilecek olan veriler tanımlanarak verinin yapısı anlaşılacaktır (Wall vd., 2012). Toplanan ve yapısı ortaya konulan veriler üzerinde ihtiyaç duyulan noktalarda bir takım düzenlemeler yapılarak veri ön işleme aşaması uygulanmaktadır (Celis ve Musicant, 2002). Analize uygun hale getirilen veriler üzerinde modeller oluşturularak veri madenciliği teknikleri uygulanmaktadır (Tenev vd., 2014). Analizler de gerçekleştirildikten sonra en son aşama ise sonuçların yorumlanarak durum değerlendirilmesi yapılması ve sonuçların rapor edilmesi şeklindedir. (Kızılkaya Aydoğan vd., 2007). Literatür incelendiğinde veri madenciliğinin birçok alanda kullanımının olduğu görülmektedir. Bu çalışmalardan bazıları şöyledir;

Berthonnaud ve arkadaşları (2005) veri madenciliği yöntemlerini kullanarak insan omurgasının dengesinin belirlenmesi üzerine çalışmışlardır. Öznitelik olarak şekil ve yön parametrelerini kullanmışlar ve insan gövdesinin denge durumunu karakterize etmeye çalışmışlardır. Çalışmalarında kullandıkları verileri toplamak için ise yüz altmış bireyin röntgen verilerini kullanmışlardır.

Burrough ve arkadaşları (2000) çalışmalarında veri madenciliği yöntemleri kullanılarak otomatik peyzaj sınıflandırma metotları konusunda yaşanan problemlerle ilgili değerlendirme yapmışlardır.

Chiu ve arkadaşları (2009) çalışmalarında geleneksel istatistiksel analiz yöntemi ve veri madenciliği yöntemlerinden olan yapay sinir ağları, küme optimizasyon yöntemleri gibi birçok akıllı kümeleme yöntemlerini birleştiren, karar destek sisteminin yapısına dayalı bir pazar bölümlenme sistemi tasarlamışlardır.

Chae ve arkadaşları (2001) çalışmalarında yüksek tansiyonun veri madenciliği yöntemleri ile belirlenmesi üzerine çalışmışlar ve önemli öznitelikleri belirlemişlerdir. Yöntem olarak logistic regression ve C5.0 gibi tahmin yöntemlerini kullanmışlardır. Çalışmalarında kullandıkları verileri ise Koredeki sağlık sigortası kurumundan temin etmişlerdir.

İşler ve Narin (2012) çalışmalarında veri madenciliği yöntemlerini kullanarak kalp yetmezliği hastalığının tahminlenmesi üzerine çalışmışlardır. Yaptıkları çalışmada ayrıca küme sayılarının başarı oranına etkisini de değerlendirmişlerdir. Sonuçlara bakıldığında zaman en yüksek başarı oranının küme sayısının dört olarak belirlendiği zaman gerçekleştiği görülmektedir.

Ganzert ve arkadaşları (2002) çalışmalarında veri madenciliği yöntemlerini kullanarak solunum basıncı hacim eğrilerini incelemişlerdir. Kullandıkları algoritma C5.0'dir. Sonuçlara bakıldığında zaman hastanın invazivliğini düşürülebileceği görülmektedir.

Coulter ve arkadaşları (2007) çalışmalarında veri madenciliği yöntemlerini kullanarak kalp kası bozukluğu ve antipsikotik ilaçları incelemişlerdir. Kullandıkları algoritma ise bayesian algoritması olmuştur.

Münz ve arkadaşları (2007) çalışmalarında veri madenciliği yöntemlerini kullanarak web trafiğinin şematize edilmesi konusunda çalışmışlar ve ayrıca, k-means kümeleme algoritmasına dayanan akış tabanlı yeni bir anomali tespit şeması sunmuşlardır.

Tatiraju ve Mehta (2008) çalışmalarında görüntülerin bölütlenmesi üzerine çalışmışlar ve yaşanan problemleri değerlendirmişlerdir. Çalışmalarının uygulama kısmında k-means de dahil olmak üzere birkaç yöntemin karşılaştırmasını yapmışlardır.

2.1. Sağlık Alanında Veri Madenciliği Kullanımı

Hastalık ile ilgili kararlar alınırken incelenen vakanın ciddiyet durumu arttıkça verilecek kararların önemi artmaktadır. Aynı zamanda söz konusu sağlık olduğu için zamana karşı bir yarış verilmektedir. Durum böyle olunca hızlı ve doğru kararlar vermenin önemi daha çok ortaya çıkmaktadır çünkü zaman ilerledikçe durumun ciddiyeti de artmaktadır. Bu kapsamda süreçlerin hızlandırılması ve zaman kaybının önüne geçilmesi çok değerli olmaktadır. Süreçlerin doğru ve hızlı ilerleyebilmesi için neredeyse tek çözüm teknolojiyi etki bir biçimde kullanmaktır. Literatür incelendiğinde sağlık alanında veri madenciliğinin kullanımının oldukça fazla olduğu görülmektedir. Bu çalışmalardan bazıları şöyledir;

Göreke ve arkadaşları (2014) çalışmalarında bilişim sistemleri ve veri madenciliği yöntemlerini kullanarak meme kanserinin teşhis edilmesi üzerine çalışmışlardır. Ayrıca teşhis için kullanılan özniteliklerden önem düzeyleri yüksek olanları belirlemişler ve belirledikleri öznitelikler ile daha yüksek oranda başarıya ulaşmışlardır.

Wu ve arkadaşları (2018) çalışmalarında veri madenciliği yöntemlerini kullanarak şeker hastalığının modellenmesi üzerine çalışmışlardır. Çalışmalarının detayına bakıldığı zaman öncelikle veri ön işleme adımlarını uyguladıkları devamında ise lojistik regresyon ve k-means yöntemlerini kullandıkları görülmektedir. Ayrıca çalışmalarında önerdikleri modeli farklı yöntemlerle karşılaştırmışlardır. Sonuçlarına bakıldığı zaman önerdikleri yöntemin karşılaştırdıkları yöntemlerden daha başarılı olduğu görülmektedir.

Khalilabad ve arkadaşları (2016) çalışmalarında veri madenciliği yöntemlerini kullanarak meme kanseri tipinin saptanması üzerine çalışmışlardır. Çalışmalarının detayına bakıldığı zaman öncelikle genlerin yerini doğru tespit edebilmek için görüntü işleme tekniklerini kullandıkları devamında ise karar ağaçlarını kullanarak meme kanseri tipini teşhis ettikleri görülmektedir. Sonuçlara bakıldığı zaman yapılan tahminlemenin başarı oranının % 95 olduğu görülmektedir.

Singh ve Sivabalakrishnan (2015) çalışmalarında birçok farklı özellik seçimi algoritmasını ve veri madenciliği yöntemini kullanarak gen ifadelerini sınıflandırmışlardır.

Tarek ve arkadaşları (2017) çalışmalarında veri madenciliği yöntemlerini kullanarak kanser sınıflandırması yapmışlardır. Kullandıkları yöntem k-nn algoritması olmuştur. Çalışmalarının detaylarına bakıldığı zaman gen ekspresyon profillerine dayanan yeni dizilimlerinde bulunmuşlardır. Sonuçlarına bakıldığı zaman ise daha önceki çalışmalardan daha hızlı ve daha geniş kapsama sahip olan bir çalışma olduğu görülmektedir.

Vanitha ve arkadaşları (2015) çalışmalarında veri madenciliği yöntemlerini kullanarak gen sınıflandırması üzerine çalışmışlardır. Kullandıkları yöntem destek vektör makinesi olmuştur. Çalışmalarının detaylarına bakıldığı zaman bilgilendirici genleri tanımlamak için genler ve sınıf etiketi arasındaki karşılıklı bilgiyi kullandıkları görülmektedir. Performansları değerlendirirken, tek noktalı çapraz doğrulama yöntemini ve iki kanser veri setini kullanmışlardır. Yaptıkları testler sonrasında en bilgilendirici alt kümeyi tanımlamışlardır. Önerdikleri yaklaşımı diğer yaklaşımlarla karşılaştırdıklarında sınıflandırma performansının daha yüksek çıktığı görülmektedir.

El-Bialy arkadaşları (2015) çalışmalarında veri madenciliği yöntemlerini kullanarak koroner arter hastalığının incelenmesi üzerine çalışmışlardır. Çalışmalarının detayına bakıldığı zaman tutarsız veri durumlarının önüne geçebilmek için farklı veri setlerine uygulanan yöntemlerin sonuçlarının entegrasyonu sağlamışlardır. Ayrıca veri setini tutarsız ve gürültülü verilerden kurtarmak için karar ağaçlarını kullanarak budamalar gerçekleştirmişler. Çalışmalarının sonucuna bakıldığı zaman sınıflandırma başarısının doğruluğunun önceki duruma göre daha yüksek olduğu görülmüştür.

Peixoto ve arkadaşları (2017) çalışmalarında veri madenciliği yöntemlerini kullanarak yoğun bakım ünitelerinin performansının iyileştirilmesi ve sağlık profesyonellerine karar vermelerinde yardımcı olunabilmesi için çalışmışlardır. Çalışmalarında kullanmak için hastanenin yoğun bakım ünitelerinden temin edilen verilerde bir takım veri madenciliği yöntemleri uygulandıktan sonra yapılan tahminlemelerinde %90 oranında başarı sağlamışlardır.

2.2. Kümeleme

Yakın geçmişte teknolojinin hızla gelişmesi, veri depolama maliyetlerinin azalması, veri tabanı sistemlerinin kullanımının artması ve sorgulama sistemlerinin gelişmesi ile birlikte veri yığınları oluşmaktadır. Oluşan bu yığın veriler içerisinde geleneksel yöntemlerle yapılan raporlamalar etkisiz kalabilmektedir (Sarıman, 2011). Bu durum bilgi keşfi, veri madenciliği gibi yeni kavramları ortaya çıkarmıştır. Veri madenciliğinin en temel tanımı büyük ölçekli verilerden anlamlı ve gerekli olan bilgiyi elde etme yolculuğudur. Veri madenciliği temel olarak veriler arasındaki desenlerin çıkarılması ve birtakım algoritmalarla modellenmesi fikrine dayanmaktadır. Böylece daha önceden fark edilmeyen örüntüler ortaya çıkarılmaktadır. Veri madenciliğinde kullanılan teknikler, üzerinde çalışılan probleme, eldeki verilere ve sonuçların kullanım amacına göre farklılık göstermektedir. Veri madenciliğinde kullanılan yöntemler temelinde tahmin edici (predictive) ve tanımlayıcı (descriptive) olmak üzere ikiye ayrılmaktadır. Tanımlayıcı modellerde sonuçları önceden belli olmayan durumlarda kümeleme, birliktelik kuralları, sıralı diziler gibi yöntemler kullanılarak veri setinin içindeki ilişkiler ortaya çıkarılmaya çalışılmaktadır. Tahmin edici modellerde ise sonuçları önceden bilinen örnek durumlardan yapılan çıkarılar sonucunda geliştirilen modeller ile sonuçları bilinmeyen yeni durumların sonuçlarının tahminlenmesi üzerine çalışılmaktadır. Tahmin edici modellerde kullanılan yöntemler ise sınıflandırma, zaman serileri ve eğri uydurma olarak sayılabilmektedir.

Kümeleme yöntemi, hangi sınıfa ait olduğu bilinmeyen elemanların sınıflandırılması amacıyla geliştirilmiştir (Yavuz vd., 2011). Bu amaca yönelik olarak, incelenen veri setleri aralarındaki benzerliklere göre gruplandırılmaktadır. Daha sonrasında oluşturulan grupların belirleyici özellikleri ortaya konulmamaktadır. Diğer bir ifade ile kümelemenin amacı, ele alınan konudaki elemanlar arasındaki var olduğu bilinen benzerliklere dayanarak daha küçük kümeler oluşturmaktır (Çınaroğlu ve Bulut 2018).

Tanımlayıcı modeller arasında yer alan kümeleme yöntemi, bir veri setindeki örnekleri belirli yakınlık kriterlerine göre bölütleme yani benzerliklerine göre gruplara ayırma işlemidir. Yapılan gruplandırmadaki her bir gruba küme adı verilmektedir. Bu sebepten dolayı yapılan işlemde kümeleme işlemi olarak adlandırılmaktadır. Kümeleme işlemi yapılırken aynı küme içindeki örneklerin benzerliğinin fazla, farklı kümeler arasındaki benzerliğin ise az olması gerekmektedir (Işık ve Çamurcu, 2007). Diğer türlü iki farklı küme arasındaki benzerlik çok fazla olur ise o iki kümenin farklı kümeler olmasına gerek yoktur ve ikisi birleştirilip tek küme haline getirilmelidir. Öğrenme türlerine göre değerlendirildiğinde kümeleme yöntemi gözetimsiz sınıflandırma yöntemine dahil edilmektedir. Gözetimsiz sınıflama ile hangi sınıfa ait olduğu önceden bilinmeyen elemanlar anlamlı bir şekilde alt kümelerine ayrılarak gruplandırılmaktadır. Kümeleme yöntemi elemanların özelliklerine göre yapılmaktadır (MacQueen, 1967). Kümeleme yönteminde kümelerin benzerlik ve farklılıkları belirlenirken hesaplanan uzaklıklar ve alternatif ölçüler kullanılmaktadır (Bradley vd., 1998). Uzaklıklar hesaplanırken kullanılan birden fazla uzaklık ölçütü bulunmaktadır. Öklid, chebychev veya manhattan bazı uzaklık ölçütleridir. En sık kullanılan uzaklık ölçütü öklid olmakla birlikte kullanılan veri setine göre bazı durumlarda diğer ölçütlerde kullanılabilir (Sarıman, 2011).

Kümeleme yönteminde her bir kümede yer alan elemanlar dâhil oldukları kümeyi diğer kümelerden ayıran ortak özelliklere sahiptir. Kümeleme sonucunda her bir eleman yalnızca bir kümeye ait olmaktadır ve böylece kümeler birbirinden kesin şekilde ayrılmaktadır. Kümeleme modellerinde amaç, Şekil 1' de görüldüğü gibi küme elemanlarının birbirlerine çok benzediği ve kümeler arasındaki benzerliklerin birbirlerinden çok farklı olduğu kümelerin oluşturulması ve veri setindeki örneklerin farklı kümelere bölünmesidir.

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ



Şekil 1: Koordinat düzleminde kümeleme örneği

Kümeleme yöntemleri ayrıca tahmin edici modellerde veri ön işleme aşamasında da, homojen veri grupları oluşturması için kullanılmaktadır.

Kümeleme yöntemleri kendi içlerinde hiyerarşik ve hiyerarşik olmayan diğer bir ifade ile bölümlenmeli kümeleme yöntemleri olarak ikiye ayrılmaktadır.

Hiyerarşik kümeleme yönteminde genellikle ağaç yapıları kullanılmaktadır. Böylelikle işleyiş anlaşılabilir eklemeler ya da çıkarmalar yapılabilmektedir. Hiyerarşik olmayan kümeleme yöntemi ise küme sayısının bilindiği ya da anlamlı olarak tahminlendiği durumlarda kullanılmaktadır. Böylece belirli sayılarda küme merkezleri belirlenmekte ve veriler bu küme merkezlerine dağıtılmaktadır. Hiyerarşik olmayan kümeleme yönteminin en bilindik örneği k-means'tir.

3. ARAŞTIRMADA KULLANILAN YÖNTEMLER

3.1. K-means

Kümeleme yapmak, benzer olanları bir araya getirerek gruplar oluşturma işlemidir (Yavuz vd., 2011). Benzer olanların bir arada toplanması, farklı olanların da ayrışması demektir (Çınaroğlu ve Bulut 2018). Bu doğrultuda oluşacak kümelerde grup içi benzerliklerin maximum, gruplar arası benzerliklerin ise minimum olması hedeflenmektedir (Işık ve Çamurcu, 2007). Kümeleme işlemi için kullanılan en eski veri madenciliği yöntemlerinden birisi olan k-means (Çınaroğlu ve Bulut 2018) 1967 yılında J.B. MacQueen tarafından geliştirilmiştir (MacQueen, 1967) ve günümüzde halen kullanılmaya devam etmektedir (Bradley vd., 1998). K-means yapısının basit olması ve başarılı sonuçlar elde edilmesinden dolayı kümeleme için çok fazla tercih edilen bir yöntem olmasının yanında görülen en büyük eksikliği küme sayısının kullanıcı tarafından sabit bir değer olarak girilmesi gerekliliğidir. Literatürde bu eksikliği gidermek bulunan bazı yöntemler mevcuttur. Bu yöntemlerden bir tanesinde x-means algoritmasıdır.

Önögreticisiz bir yöntem olan k-means (Doğan vd., 2018) çalıştırıldığı zaman eldeki verilerin hangi kümelere ait olduğu belli değildir (Sariman, 2011). K-means yöntemindeki k harfi oluşturulmak istenen küme sayısını ifade etmektedir (Bilgin ve Çamurcu, 2005) ve algoritma çalıştırılmadan önce kullanıcı tarafından belirlenmiş şekli ile algoritmaya parametre olarak girilmelidir (Khaled vd., 1998). Oluşturulacak olan her bir küme, o kümeyi temsil eden bir küme merkezine sahip olmak zorundadır. Bu sebepten dolayı kümeler belirlenirken öncelikle girilen k parametresi kadar rasgele küme merkezleri oluşturulmaktadır (Güner vd., 2018). Her bir elemanın rasgele seçilen küme merkezlerine olan uzaklıkları hesaplandıktan sonra elemanlar en yakın kümeye atanmaktadır. (Işık ve Çamurcu, 2011). Atama işlemi gerçekleştirildikten sonra oluşan kümelerin küme merkezleri yeniden hesaplanmakta ve her bir elemanın yeni küme merkezlerine olan uzaklıkları yeniden

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

hesaplanmaktadır. Küme merkezleri ilk olarak rasgele belirlenmekle birlikte eleman atamaları yapıldıktan sonra yeniden hesaplanırken aritmetik ortalama kullanılmaktadır. Yani kümeye atanan her elemanın boyutları ayrı ayrı toplanmakta ve eleman sayısına bölünmektedir. Bu işlem her bir elemanın bulunduğu küme sabitleninceye kadar devam ettirilmektedir (Demiralay ve Çamurcu 2005). Tüm elemanların dahil olduğu küme aynı olduğu zaman algoritma durdurulmaktadır (Tekin vd., 2011). Böylece mesafe olarak birbirine daha yakın olan elemanların bir kümede toplanması sağlanmaktadır (Tan vd., 2006)

K-means'te elemanların her bir küme merkezlerine olan uzaklıkları öklid uzaklığı, chebychev uzaklığı veya city-block (manhattan) uzaklığı kullanılarak hesaplanabilmektedir. Kullanımı en yaygın olan uzaklık olduğundan dolayı bu çalışmada da öklid uzaklığı tercih edilmiştir. Öklid uzaklığı ile iki nota arasındaki doğrusal uzaklık hesaplanmaktadır ve uzaklık azaldıkça benzerlik de artmaktadır şeklinde yorumlanmaktadır (Güner vd., 2018). Öklid uzaklığı hesaplamak istenen $A = \{x_1, x_2, \dots, x_n\}$ ve $B = \{y_1, y_2, \dots, y_n\}$ noktaları olduğu düşünülür ise eşitlik 1'deki formül kullanılmaktadır (Taşçı ve Onan 2016).

$$\text{Öklid uzaklığı (A, B)} = \left(\sqrt{\sum_{i=1}^n (x_i - y_i)^2} \right) \quad 1)$$

Belirlenen k adet küme için k-means algoritmasının çalışma şekli aşağıdaki verilmiştir.

- 1) İlk olarak, girilen k parametresi kadar rasgele küme merkezleri oluşturulmaktadır.
- 2) Her elemanın, k parametresi kadar belirlenen tüm küme merkezlerine olan uzaklıkları tek tek hesaplanmakta ve elemanlar en yakın olan kümeye atanmaktadır.
- 3) Elemanlar en yakın oldukları kümeye atandıktan sonra oluşan yeni kümelerin, küme merkezleri tekrardan hesaplanmaktadır.
- 4) Herhangi bir elemanın bulunduğu küme de değişiklik olur ise, 2. Adıma dönmekte ve algoritma devam ettirilmekte, hiçbir elemanın ait olduğu küme de değişiklik olmaz ise algoritma sonlandırılmaktadır. (Doğan vd., 2018).

K-means literatürde sıkça kullanılan bir yöntemdir. Yapılan çalışmalardan bazıları şunlardır;

Alsabti ve arkadaşları (1997) k-means yöntemini temel alarak oluşturulan yeni bir yöntem üzerinde çalışmışlardır. Çalışmalarının detayına bakıldığı zaman prototipe en yakın olan tüm kalıpları verimli bir şekilde bulabilmek için önerdikleri yöntemde k-dimensional tree algoritmasını kullandıkları görülmektedir.

Ng ve arkadaşları (2006) çalışmalarında tıbbi görüntüleme için k-means ve su havzası segmentasyon algoritmasının güçlü yönlerini kullanarak oluşturdukları yeni bir yöntem üzerinde çalışmışlardır.

Dhanachandra ve arkadaşları (2015) çalışmalarında görüntüler üzerinde kümeleme yapmak için k-means algoritmasını kullanmışlardır.

Celik (2009) çalışmasında temel bileşen analizi ve k-means kümelemesini kullanarak çok uçlu uydu görüntülerinde denetimsiz değişikliklerin tespit edilmesi için yeni bir teknik üzerinde çalışmıştır. Çalışmasının detaylarına bakıldığı zaman k-means yöntemini özellik vektör uzayını iki kümeye bölmek için kullanmıştır.

Khan ve Ahmad (2004) çalışmalarında k-means yöntemindeki k parametresinin belirlenmesi konusunda yeni bir algoritma önermişlerdir. Çalışmalarının deneysel sonuçlarına bakıldığı zaman önerilen algoritma kullanıldığında elde edilen sonuçların tutarlı olduğu görülmektedir.

Dehariya ve arkadaşları (2010) çalışmalarında görüntülerin kümelemesi konusunda k-means ve bulanık k-means yöntemlerini karşılaştırmışlardır. Çalışmanın uygulamasını yaparlarken k-means ve bulanık k-means algoritmalarının ikisine de aynı prosedürleri uygulamışlardır. Çalışmalarının

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

deneysel sonuçlarına bakıldığı zaman kullandıkları görüntüleri kümeleme konusunda bulanık mantık ile optimize edilmiş k-means algoritmasının, normal k-means algoritmasına göre daha yüksek performans gösterdiği görülmüştür.

Güneş ve arkadaşları (2010) çalışmalarında veri madenciliği yöntemlerini kullanarak uyku evrelerinin otomatik olarak skorlanması üzerine çalışmışlar ve k-means kümeleme yöntemine dayalı olarak yeni bir önileme yöntemi geliştirmişlerdir. Çalışmalarını detaylarına bakıldığı zaman öncelikle EEG (Elektroensefalografi) sinyaline ait frekansları çıkarmışlar devamında bu çıkarımlardan özellik seçimi gerçekleştirmişlerdir. Elde ettikleri öznelik sayısı 129 olmuştur. Minimum değer, maksimum değer, standart sapma ve ortalama değer içeren istatistiksel yöntemleri kullanarak özellikleri azaltmış 4'e düşürmüşlerdir. Devamında belirlenen özellikler yardımı ile uyku evrelerini otomatik olarak sınıflandırmışlardır. Son aşamada ise yapılan sınıflandırmadaki performansları değerlendirmişler ve umut vadeden sonuçlara ulaşmışlardır.

Orhan ve arkadaşları (2011) çalışmalarında epilepsi tedavisinde tanısal karar destek mekanizması olarak çok katmanlı algılayıcı sinir ağına dayalı yeni yeni bir sınıflandırma modeli üzerine çalışmışlardır. Çalışmaların uygulama kısmında EEG sinyallerini frekans alt bantlarına ayırmışlar ve k-means algoritmasını kullanılarak her frekansı alt kümelerine ayırmışlardır. Sonuçlarında önerdikleri modelin performans değerlendirmesini yapmışlar ve sınıflandırma doğruluğunun oranlarını çıkarmışlardır.

Ravichandran ve Ananthi (2009) çalışmalarında insan derisinin sınıflandırılması üzerine çalışmışlardır. Çalışmaların detaylarına bakıldığı zaman cilt alanlarını tespit etmek için küme bazlı k-means tekniğini kullanarak cilt tespiti yaptıkları görülmektedir. Ayrıca kullandıkları yöntemi birçok görüntü üzerinde test etmişler ve performanslarını değerlendirmişlerdir. Sonuçlara bakıldığı zaman yüksek oranlarda başarının elde edildiği görülmektedir.

Redmond ve Heneghan (2007) çalışmalarında k-means yönteminde k parametresinin başlangıç değerinin belirlenmesi üzerine çalışmışlar ve bu amaç doğrultusunda yeni bir yöntem geliştirmişlerdir. Önerdikleri yöntemi temelinde k-dimensional tree algoritmasının çalışma yapısına dayandırmışlardır. Böylece kd-tree'yi kullanarak verilerinin yoğunluğunun nerelerde olduğunu belirleyebilmişlerdir. Devamında elde ettikleri yoğunluk bilgisini kullanarak kümeleme yapmışlardır. Çalışmalarında önerdikleri yöntemi test etmek için ise UCI Machine Learning Repository'den elde ettikleri 2 veri setini kullanmışlar ve performansları değerlendirmişlerdir.

He ve arkadaşları (2013) çalışmalarında k-means yöntemini temel alarak karma bir model üzerinde çalışmışlar ve yeni bir model sunmuşlardır.

Wu ve arkadaşları (2007) çalışmalarında veri madenciliği yöntemlerini kullanarak beyin görüntülerinde tümör nesnelere belirlenmesi üzerine çalışmışlardır. Yöntem olarak k-means kümeleme tekniğini kullanmışlar ve renk temelli yeni bir segmentasyon yöntemi üzerinde durmuşlardır. Çalışmalarını detaylarına bakıldığı zaman öncelikle renk tabanlı segmentasyon oluşturulduğu, oluşturulan bu renk tabanlı segmentasyon üzerinde ki gri görüntülerin renk uzay görüntüsüne dönüştürüldüğü ve daha sonra k-means kümeleme yöntemi kullanılarak tümör nesnelere konumunun bir diğer öğelerinden ayrıldığı görülmektedir. Çalışmalarının sonuçlarına bakıldığı zaman kullanılan yöntemin, Manyetik Rezonans Görüntüleme ile elde edilen beyin görüntülerinde patolojilerin lezyon büyüklüğünün ve bölgesinin tam olarak ayırt etmesine yardımcı olacak oranlarda başarılı sonuçlar elde edildiği görülmektedir.

Babu ve Murty (1993) çalışmalarında genetik algoritmayı kullanarak k-means algoritmasında ki başlangıç parametresi için uygun değer belirlenmesi için çalışmışlardır.

K-means algoritmasında uygun başlangıç değerlerinin belirlenmesi üzerine çalışmışlardır. Aynı zamanda veri setinin en uygun bölünmesini sağlamak için de genetik algoritma kullanmışlardır. Elde edilen sonuçlara bakıldığı zaman umut veren değerlere ulaşıldığı görülmektedir.

Liu ve arkadaşları (2007) çalışmalarında trafik sınıflandırmasındaki sorunları değerlendirmişlerdir. Makine öğrenmesi temelli yöntemleri göz önüne alarak, verimliliği ve

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

performansı değerlendirmişlerdir. Deneysel çalışmaları için kullandıkları yöntem denetimsiz k-means algoritması olmuştur. Ayrıca kullandıkları veri setindeki verimliliği arttırmak için öznitelik seçimi de gerçekleştirmişlerdir. Sonuçlara bakıldığı zaman başarı oranında istedikleri artışı yakaladıkları görülmektedir.

Singh ve arkadaşları (2011) çalışmalarında k-means algoritması, sezgisel k-means algoritması ve bulanık c-means algoritmasını kullanarak metin belgelerinin kümelemesi üzerine çalışmışlardır. Çalışmalarının detaylarına bakıldığı zaman öncelikle özellik çıkarımı yaptıkları ve devamında bu çıkarımların performansa etkilerini değerlendirdikleri görülmektedir. Uygulamalarında bazı standart veri kümeleri üzerinde çalışmışlardır. Aynı zamanda kullandıkları algoritmalarda performans değerlendirmesi için birçok ölçüt kullanarak sonuçları değerlendirmişlerdir.

Fırat ve arkadaşları (2012) çalışmalarında veri madenciliği yöntemlerini kullanarak yıllık olarak yağış toplamlarının sınıflandırılması ve homojen bölgelerin belirlenmesi konusunda çalışmışlardır. Yöntem olarak kullanımı basit olan ve çok yaygın olarak kullanılan bir kümeleme yöntemi olan k-means yöntemini kullanmışlardır. Çalışmaları için gerekli olan verileri Türkiye genelinde Devlet Meteoroloji İşleri tarafından işletilen 188 yağış gözlem istasyonundan temin etmişlerdir. Kullandıkları verilerin detaylarına bakıldığı zaman yıllık yağışlar, enlem, boylam ve yükselti verilerini kullandıkları görülmektedir. Çalışmalarının sonuçlarına bakıldığı zaman ise yaptıkları testlerden sonra küme sayısını 7 olarak belirledikleri görülmektedir.

KarsligEl ve arkadaşları (2017) çalışmalarında veri madenciliği yöntemlerini kullanarak ağ saldırılarının tespit edilmesi üzerine çalışmışlar ve yeni bir yarı denetimli tespit sistemi tasarlamışlardır. Tasarladıkları model içinde kümeleme yapak için k-means algoritmasını kullanmışlardır. Yaptıkları tasarımın detaylarına bakıldığı zaman öncelikle eğitim aşaması olarak k-means algoritmasını kullanmışlar ve kümelere ayırma işlemini gerçekleştirmişlerdir. Devamında normal ve anormal örnekler arasında ayırım yapabilmek için kümelerin merkezlerinden uzaklıklarına göre bir eşik değeri hesaplanmışlardır. Hesaplamadıkları eşik değerini kullanarak ağdaki anormallikleri belirlemeye çalışmışlardır. Tasarladıkları yöntemin performansını değerlendirmek için ise etiketli bir ağ bağlantı izleri veri kümesi olan NSL-KDD veri setini kullanmışlardır. NSL-KDD veri setinde gerçekleştirdikleri test sonuçlarına bakıldığı zaman % 80 oranında bir doğruluk elde ettikleri görülmektedir.

Sönmez ve Kömüşcü (2007) çalışmalarında veri madenciliği yöntemlerini kullanarak Türkiye'nin ana yağış bölgeleri belirlenmeye çalışmışlardır. Yöntem olarak k-means kümeleme algoritmasını kullanmışlardır. Zaman periyodu olarak 1977-2006 yılları arasını almışlar ve 148 noktada K-means kümeleme yöntemi ile yağış verileri sınıflandırarak benzer özellikler gösteren istasyonları bölgelerine ayırmışlardır. Yaptıkları kümelemede uygun küme sayısının belirlemek için en düşük negatif silüet sayısı ve maximum ortalama silüet değerlerini kullanmışlardır. Çalışmalarının sonucuna bakıldığı zaman 1977-2006 yılları arası için yapıtlıkları kümeleme sonucunda en uygun yağış bölgesi sayısını 6 olarak belirledikleri görülmektedir.

Erişti ve Tümen (2012) çalışmalarında veri madenciliği yöntemlerini kullanarak güç kalitesindeki harmonik bozulmalar üzerinde çalışmışlardır. Çalışmalarında kullandıkları verileri, elektrik dağıtım sistemine yerleştirdikleri güç kalitesi analizörü aracılığıyla toplamışlardır. Belirli sürelerde elde ettikleri farklı seviyelerdeki harmonik bileşenlerini ise k-means algoritmasını kullanarak kümelemişlerdir.

Işık ve Çamurcu (2007) çalışmalarında kümeleme yöntemlerinden olan k-means, k-medoids ve bulanık c-means algoritmalarını kullanarak yöntemleri karşılaştırmışlardır. Performans değerlendirmesi yapmak için gerçekleştirdikleri çalışmalarında her yöntem için literatürde kabul görmüş aynı veri setini kullanmışlardır. Yaptıkları analiler sonucunda kümeleri ve küme merkezlerini bulan en başarılı yöntemin k-medoids algoritması olduğunu, örtüşen kümeleri belirlemede bulanık c-means algoritmasının diğerlerinden daha başarılı olduğunu, zaman açısından bakıldığında ise en avantajlı algoritmanın k-means algoritması olduğunu belirlemişlerdir.

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

Demiralay ve Çamurcu (2005) çalışmalarında hiyerarşik kümeleme algoritmalarından CURE ve AGNES yöntemleri ile bölümleyici kümeleme algoritmalarından k-means yönteminin karşılaştırmasını yapmışlardır. Sonuçlarına bakıldığı zaman küresel kümeleri bulma konusunda CURE ve AGNES algoritmalarının k-means algoritmasına göre daha başarılı olduğu, sıkışık bulutlar halindeki kümelerde ise benzer sonuçlar verdiği tespitlerde bulunmuşlardır.

Yürük ve Erdoğan (2015) çalışmalarında hayvansal atıklarından biyogaz potansiyelinin hesaplanması üzerinde çalışmışlar ve tesisleri konumlarına göre kümelemişlerdir. Bölge olarak Düzce ili ve ilçelerini örnek almışlar yöntem olarak ise k-means algoritmasını kullanmışlardır.

Bilgin ve Çamurcu (2005) çalışmalarında kümeleme algoritmalarından olan DBSCAN, OPTICS yöntemleri ile k-means algoritmasını karşılaştırmışlardır.

3.2. X-means

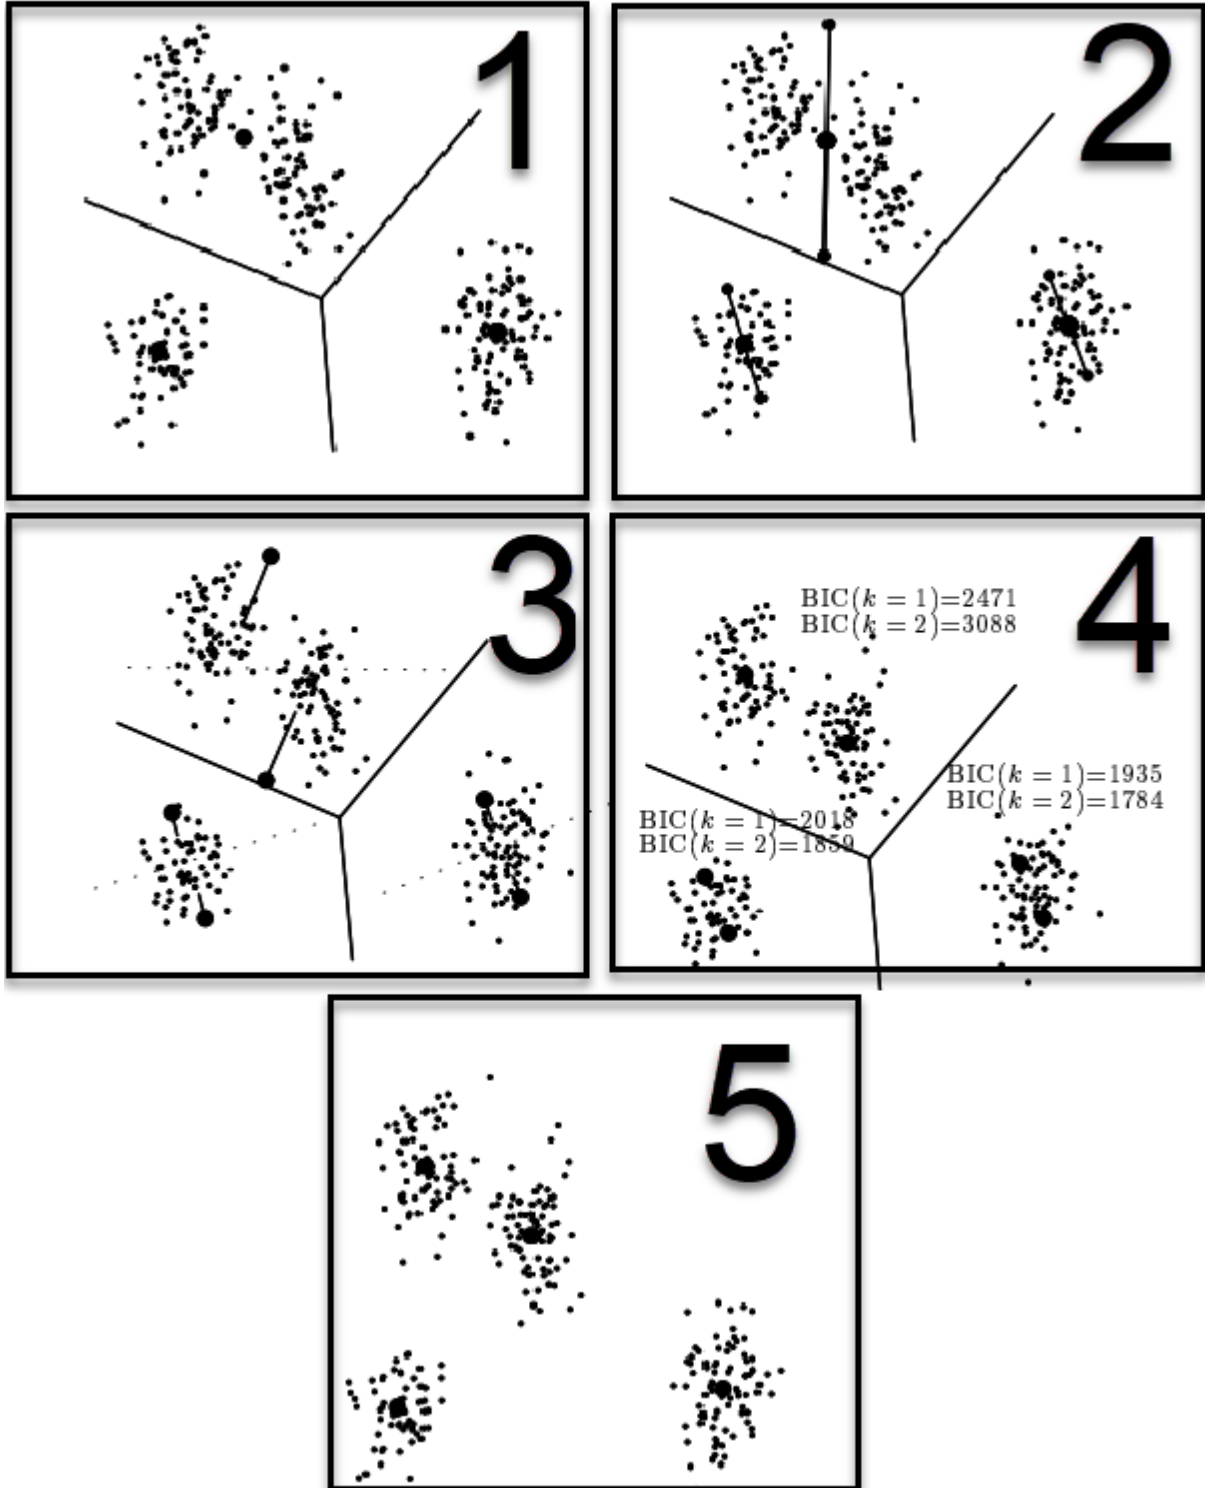
K-means algoritması en temel kümeleme algoritmalarından bir tanesi olmasının yanında en büyük eksikliği oluşturulacak olan küme sayısının kullanıcı tarafından girilmesi gerekliliğidir (Akçapınar vd., 2016). Küme sayılarını belirlemek bazı veri setleri için kolay olmakla birlikte bazı veri setleri için oldukça zor ve karmaşıktır. Bu sebepten dolayı algoritmayı tek bir küme sayısı ile çalıştırmak bazı durumlarda daha iyi olabilecek alternatiflerin göz ardı edilebilmesi anlamını taşımaktadır. (Pelleg ve Moore, 2000). Bu eksikliği gidermek için literatürde k-meansin geliştirilmesi ile elde edilen birkaç yöntem mevcuttur. Bu yöntemlerden bir tanesi de x-means algoritmasıdır (Tsai ve Chiu, 2008). X-means algoritması 2000 yılında Pelleg ve Moore tarafından geliştirilmiştir (Akçapınar vd., 2016). Temelde k-means algoritmasının çalışma yapısının kullanan x-means algoritması (Kalogeratos ve Likas, 2012), k-means algoritmasına ek olarak küme sayısını verilen aralıktaki değerler arasından kendisi belirlemektedir (Steinley, 2006) Böylece oluşacak küme sayısı için sabit bir değer yerine daha geniş aralıktaki ihtimaller değerlendirilerek belirlenmektedir (Mühr ve Granitzer, 2009).

X-means algoritması içerisinde tekrarlı olarak k-means algoritması çalıştırılmaktadır (Feng ve Hamerly, 2007). K parametresi, girilen aralık değerleri içindeki en düşük değerden başlayacak şekilde seçilerek küme merkezleri oluşturulmaktadır. K-means her çalıştırdıktan sonra oluşan kümelere hangilerinin kendilerini bölmeleri gerektiği sorusunun cevabını bulmak için bayesin bilgi kriteri (BIC) değerini hesaplanmaktadır (Bholowalia ve Kumar, 2014). Bölünmenin gerçekleştiği kümeye ebeveyn, oluşan yeni kümelere ise yavru merkez denilmektedir (Jain, 2010) ve bu bilgiler listeler halinde tutulmaktadır (Hamerly ve Elkan, 2004). Kümlerdeki bölünme, k parametresi girilen aralık içerisindeki en yüksek değere ulaşmaya kadar devam ettirilmektedir (Tucker vd., 2010) ve her iterasyonda BIC değerleri yeniden hesaplanmaktadır. Hesaplanan BIC değerleri içerisinde hep en iyi olan sonuçlar kaydedilmektedir. Her yeni BIC değeri hesaplandığında bir önceki kayıta tutulan en iyi BIC değeri ile kıyaslanmakta ve değer öncekinden daha iyi ise eski en iyi değer silinerek yerine yeni en iyi değer değiştirilerek yeniden kaydedilmektedir (Pelleg ve Moore, 2000). Böylece daha iyi BIC değerleri elde edildikçe en iyi değer sürekli olarak güncellenmektedir ve en sonunda en yüksek değere sahip olan merkezlerde karar kılınmaktadır (Bholowalia ve Kumar, 2014).

Bu şekilde k parametresini belirlemek için girilmiş olan aralıktaki en düşük değerden en yüksek değere gelinceye kadar olan tüm ihtimaller değerlendirildikten sonra sonuçlar doğrultusunda en doğru olan küme sayısı da ortaya konulmuş olmaktadır. Böylece kullanıcı tarafından girilen aralıktaki tüm k değerlerinin değerlendirilme şansı olmaktadır.

X-means algoritmasının çalışma yapısı şekil 2'deki örnekdeki aşamalarından oluşmaktadır.

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ



Şekil 2: X-means algoritmasının çalışma yapısı örneği

Şekil 2'deki numaralandırılmış işlemler x-means algoritmasının çalışma yapısını temsil edecek şekilde sıralanmıştır. Numaralandırılmış adımlar ile gerçekleştirilen işlemler şöyledir.

1 numaralı aşamada 3 tane küme merkezi olan ve küme sınırları belirlenmiş bir k-means yapısı vardır. 2 numaralı aşama ile her merkez ikiye bölünmeye başlamaktadır. Bu aşamada önemli olan yeni merkez noktalarının önceki merkez noktasına eşit uzaklıkta seçilmesidir. Belirlenen yeni merkezler için yerel olarak k-means algoritması çalıştırılmaktadır. 3 numaralı aşamada yerel olarak çalıştırılan k-means algoritmasının durumu görülmektedir. 4 numaralı aşamada yerel k-means algoritmasının

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

sonuçları ve hesaplanan BIC değerleri görülmektedir. 4 numaralı aşamada hesaplanan eski küme merkezlerinin ya da yeni küme merkezlerinin hangisinin kalacağı belirlenmektedir. Bu işlem belirlenen aralıktaki tüm değerler için devam ettikten sonra en son aşama olan 5 numaralı aşamaya geçilmektedir. 5 numaralı aşamada ise belirlenen kümeler ve küme merkezleri yer almaktadır.

4. ARAŞTIRMADA KULLANILAN VERİ SETİ

Çalışmada kullanılan veri seti 2009-2013 yılları arasında Portekiz'in Coimbra şehrinde bulunan Coimbra Hastanesi ve Üniversite Merkezi, Kadın Hastalıkları Bölümüne başvuran toplamda 166 bireyden alınan bilgiler ile oluşturulmuştur. Her bireyin Age (years), BMI, Glucose (mg/dL), Insulin (μ U/mL), HOMA, Leptin (ng/mL), Adiponectin (μ g/mL), Resistin (ng/mL), MCP-1(pg/dL) değerleri öznitelik olarak kullanılmıştır. Bu değerlerin karşılığında ise bireylerin meme kanseri tanısı yer almaktadır. Veri seti UCI machine learning repository sitesinden temin edilmiştir ve veri setinin ismi Breast Cancer Coimbra Data Set'tir (<https://archive.ics.uci.edu/ml/index.php>, 15.03.2019). Kullanılan veri setindeki özniteliklerin ismi paylaşılan kaynaktaki orijinal hali ile kullanılmış herhangi bir dil çevirisinde bulunulmamıştır. Veri setinin isimleri ve değerleri ile alakalı bilgiler Tablo 1'de gösterilmiştir.

Tablo 1 : Kullanılan veri setinin bilgileri

Öznitelik numarası	Öznitelik ismi	Minimum değer	Maximum değer
1	Age (years)	24	89
2	BMI	18,37	38,579
3	Glucose (mg/dL)	60	201
4	Insulin (μ U/mL)	2,432	58,46
5	HOMA	0,467	25,05
6	Leptin (ng/mL)	4,311	90,28
7	Adiponectin (μ g/mL)	1,656	38,04
8	Resistin (ng/mL)	3,21	82,1
9	MCP-1(pg/dL)	45,843	1698,44
10	Labels (output)	1=Healthy controls	2=Patients

Tablo 1'de görüldüğü gibi 1 tanesi sonuç olmak üzere 10 tane öznitelik mevcuttur. Yine Tablo 1'de görüldüğü gibi girdi için kullanılacak özniteliklerin tamamı sayısal veri tipindeki değerlere sahip yalnızca sonuç özniteliği katagorik veri tipine sahiptir. Sonuç etiketi ise Tablo 1'deki 1 numaradan 9 numaraya kadar olan öznitelikler karşılığında bireyin sağlık durumunu ifade edecek şekilde etiketlenmiştir. Bu çalışmada da her bir birey için çıktı etiketleri dışarda bırakılarak toplamda 9 girdi özniteliği kullanılmış ve hem k-means yöntemi hem de x-means yöntemi kullanarak kümelendirilmiştir. Devamında ise belirlenen kümelerdeki elemanların doğru kümede olup olmadığının belirlenmesi için tahminlenen kümeler ile gerçek çıktılar karşılaştırılmış ve başarı oranları belirlenerek karşılaştırılmıştır.

5. BULGULAR VE DEĞERLENDİRME

Bu çalışmada 2009-2013 yılları arasında Portekiz'in Coimbra şehrinde bulunan Coimbra Hastanesi ve Üniversite Merkezi, Kadın Hastalıkları Bölümüne başvuran toplamda 166 bireyden alınan bilgiler ile oluşturulmuş Breast Cancer Coimbra Data Set k-means ve x-means yöntemleri ile kümelendirilmiş yöntemlerin performansları karşılaştırılmıştır. Kullanılan veri setindeki öznitelikler şöyledir; Age (years), BMI, Glucose (mg/dL), Insulin (μ U/mL), HOMA, Leptin (ng/mL), Adiponectin (μ g/mL), Resistin (ng/mL), MCP-1(pg/dL).

K-means ile yapılan kümeleme sonucunda öznitelikler için belirlenen merkez değerleri Şekil 3'de verilmiştir.

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

Öznitelik ismi	Cluster 0	Cluster 1
Age	81	74
BMI	31.640368	28.650138
Glucose	100	88
Insulin	9.669	3.012
HOMA	2.38502	0.653805
Leptin	38.8066	31.1233
Adiponectin	10.636525	7.65222
Resistin	29.5583	18.35574
MCP	426.175	572.401

Şekil 320: K-means ile öznitelikler için belirlenen merkez değerler

K-means ile yapılan kümeleme sonucunda elde edilen değerler Şekil 4'de detaylı olarak verilmiştir.

```
Time taken to build model (full training data) : 0.01 seconds

=== Model and evaluation on training set ===

Clustered Instances

0      46 ( 40%)
1      70 ( 60%)

Class attribute: Class/ASD
Classes to Clusters:

  0 1 <-- assigned to cluster
20 32 | 1
26 38 | 2

Cluster 0 <-- 1
Cluster 1 <-- 2

Incorrectly clustered instances :      58.0      50      %
```

Şekil 421: K-means ile yapılan kümeleme sonuçları

Şekil 4'de görüldüğü gibi 116 örneğin tamamı eğitim verisi olarak kullanılarak k-means algoritması ile kümelendiği görülmektedir. Sınıflandırılan örnek sayısı 116 örnek içerisinde 58 tane olmuştur. Bu sayının doğruluk yüzdesine bakıldığı zaman ise %50 olduğu görülmektedir. Kalan 58 örneğin ise yanlış sınıflandırıldığı görülmüştür ve oran olarak bakıldığında yanlış sınıflandırılan örneklerin %50 oranında olduğu görülmektedir. Ayrıca k-means ile yapılan modellemenin süresine bakıldığı zaman 1 salise olduğu görülmektedir.

X-means ile yapılan kümeleme sonucunda öznitelikler için belirlenen merkez değerleri Şekil 5'de verilmiştir.

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

Öznitelik ismi	Cluster 0	Cluster 1
Age	56.775510204081634	57.6865671641791
BMI	31.89690086795918	24.42651811119402
Glucose	106.59183673469387	91.35820895522389
Insulin	14.766102040816321	6.5352686567164175
HOMA	4.310505487183672	1.5134893820597013
Leptin	41.32633061224489	15.856105970149256
Adiponectin	8.688318571428571	11.272444328358208
Resistin	18.908438163265306	11.667142835820897
MCP	679.4585714285714	428.74002985074617

Şekil 522 : X-means ile belirlenen küme merkezler

X-means ile yapılan kümeleme sonucunda elde edilen değerler Şekil 6'da detaylı olarak verilmiştir.

```
Distortion: 56.185787
BIC-Value : 82.041179
```

```
Time taken to build model (full training data) : 0.03 seconds
```

```
=== Model and evaluation on training set ===
```

```
Clustered Instances
```

```
0      49 ( 42%)
1      67 ( 58%)
```

```
Class attribute: Class/ASD
Classes to Clusters:
```

```
  0  1 <-- assigned to cluster
 21 31 | 1
 28 36 | 2
```

```
Cluster 0 <-- 2
Cluster 1 <-- 1
```

```
Incorrectly clustered instances :      57.0      49.1379 %
```

Şekil 6 : X-means ile yapılan kümeleme sonuçları

Şekil 6'de görüldüğü gibi 116 örneğin tamamı eğitim verisi olarak kullanılarak x-means algoritması ile kümelendiği görülmektedir. Sınıflandırılan örnek sayısı 116 örnek içerisinde 59 tane olmuştur. Bu sayının doğruluk yüzdesine bakıldığı zaman ise %50.8621 olduğu görülmektedir. Kalan 57 örneğin ise yanlış sınıflandırıldığı görülmüştür ve oran olarak bakıldığında yanlış sınıflandırılan örneklerin %49.1379 oranında olduğu görülmektedir. Ayrıca x-means ile yapılan modellemenin süresine bakıldığı zaman 3 salise olduğu görülmektedir.

6. SONUÇ

Bu çalışmada yeni bir algoritma önerilmemiştir. Yalnızca bilgilendirme içerikli bir karşılaştırma ile yetinilmemiştir. Kullanılan yöntemler k-means ve x-means olmuştur. Çalışmada kullanılan algoritmalar, aynı platformda gerçekleştirilmiş ve aynı veri seti kullanılarak uygulanmıştır. Yapılan karşılaştırma ile incelenen iki algoritmanın ürettiği sonuçlar değerlendirilmiş ve başarı oranı daha yüksek olan algoritma belirlenmiştir.

Çalışmada 2009-2013 yılları arasında Portekiz'in Coimbra şehrinde bulunan Coimbra Hastanesi ve Üniversite Merkezi, Kadın Hastalıkları Bölümüne başvuran toplamda 166 bireyden alınan bilgiler ile oluşturulmuş Breast Cancer Coimbra Data Set k-means ve x-means yöntemleri ile kümelenebilir yöntemlerin performansları karşılaştırılmıştır. Toplamda 116 örnekten oluşan veri seti iki sınıf içermektedir ve sınıf etiketleri 1 ve 2 ile etiketlenmiştir. Kullanılan veri setindeki öznitelikler şöyledir; Age (years), BMI, Glucose (mg/dL), Insulin (μ U/mL), HOMA, Leptin (ng/mL), Adiponectin (μ g/mL), Resistin (ng/mL), MCP-1(pg/dL). Veri seti üzerinde kümeleme işlemi yapılacağından veriler eğitim ve test verisi olarak iki parçaya ayrılmamış tüm veriler eğitim verisi olarak kullanılmıştır. Toplamda iki sınıf olduğu belli olduğu için oluşacak küme sayısının da iki olması için k-means çalıştırılırken k parametresi iki olarak girilmiştir. Yapılan sınıflandırmanın başarı oranına bakıldığı zaman k-means 116 örnekten 58 tanesini doğru sınıflandırmıştır ve başarı oranı %50,0000'dir. X-means ile yapılan kümeleme de, k parametresinin algoritma tarafından belirlenebilmesi için 2 ile 4 dahil olacak şekilde 2 ve 4 aralığı verilmiştir. Bu aralık içerisinde x-meansin belirlediği küme sayısı iki olmuştur. Yani x-means verilen aralık içerisinde doğru olan küme sayısını belirleyebilmiştir. X-meansin performansına bakıldığı zaman 116 örnekten 59 tanesini doğru sınıflandırmıştır ve başarı oranı %50,8621'dir. İki algoritmanın da başarı oranı çok yüksek olmamakla birlikte x-meansin, k-meansden 1 örnek daha fazla doğru sınıflandırarak daha yüksek bir performansa sahip olduğu görülmüştür.

Ayrıca modellemelerin gerçekleştirilme süresine bakıldığı zaman k-means ile kurulan modelin 1 salisede x-means ile yapılan modellemenin ise 3 salisede kurulduğu görülmektedir. Bu durumda x-means ile gerçekleştirilen modelin daha uzun sürede kurulduğu ama performans olarak daha yüksek sonuçlar verdiği, k-means ile gerçekleştirilen modelin ise daha kısa sürede kurulduğu ama performans olarak daha düşük sonuçlar verdiği yorumu yapılabilmektedir.

Sonuç olarak bu çalışma ile k-means ve x-means algoritmalarının uygulanması ile elde edilen sonuçlar ışığında performanslar karşılaştırılmıştır. Elde edilen sonuçlara bakıldığı zaman süre olarak k-means algoritmasının daha hızlı, x-means algoritmasının ise daha yüksek başarıya sahip olduğu görülmüştür.

İleriki çalışmalar da ise iki yöntemin karşılaştırılmasında daha genel yorumlara ulaşabilmek için daha fazla veri seti ile denemeler gerçekleştirilebilir.

Diğer kümeleme yöntemlerini de karşılaştırmak için farklı kümeleme yöntemlerini çoğaltarak daha geniş bir açıdan performans karşılaştırması da gerçekleştirilebilir.

Veri seti üzerinde veri ön işleme aşamaları gerçekleştirilerek aynı yöntemler ile daha yüksek başarı oranlarına ulaşmak için çalışılabilir.

7. KAYNAKÇA

Akçapınar, G., Altun, A., & Aşkar, P. (2016). Çevrimiçi öğrenme ortamındaki benzer öğrenci gruplarının kümeleme yöntemi ile belirlenmesi. Eğitim Teknolojisi Kuram Ve Uygulama, 6(2), 46-64. DOI: 10.17943/etku.91440.

Albayrak, A. S. ve Koltan Yılmaz, Ş. (2009). Veri madenciliği: karar ağacı algoritmaları ve imkb verileri üzerine bir uygulama. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14 (1), 31-52.

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

Alsabti, K., Ranka, S., & Singh, V. (1997). An efficient k-means clustering algorithm. *Electrical Engineering and Computer Science*, 43.

Babu, G. P., & Murty, M. N. (1993). A near-optimal initial seed value selection in k-means means algorithm using a genetic algorithm. *Pattern Recognition Letters*, 14(10), 763-769.

Berthonnaud, E., Dimnet, J., Roussouly, P., & Labelle, H. (2005). Analysis of the sagittal balance of the spine and pelvis using shape and orientation parameters. *Clinical Spine Surgery*, 18(1), 40-47.

Bholowalia, P., & Kumar, A. (2014). EBK-Means: a clustering technique based on elbow method and k-means in wsn. *International Journal of Computer Applications*, 105(9).

Bilgin, T. T., & Çamurcu, Y. (2005). Dbscan, optics ve k-means kümeleme algoritmalarının uygulamalı karşılaştırılması. *Politeknik Dergisi*, 8(2), 139-145.

Bradley, P. S., Fayyad, U. M., & Reina, C. (1998, August). Scaling clustering algorithms to large databases. In *KDD (Vol. 98, pp. 9-15)*.

Burrough, P. A., van Gaans, P. F., & MacMillan, R. A. (2000). High-resolution landform classification using fuzzy k-means. *Fuzzy Sets and Systems*, 113(1), 37-52.

Celik, T. (2009). Unsupervised change detection in satellite images using principal component analysis and k-means clustering. *IEEE Geoscience and Remote Sensing Letters*, 6(4), 772-776.

Celis, S., & Musicant, D. R. (2002). Weka-parallel: machine learning in parallel. In *Carleton College, CS TR*.

Chiu, C. Y., Chen, Y. F., Kuo, I. T., & Ku, H. C. (2009). An intelligent market segmentation system using k-means and particle swarm optimization. *Expert Systems with Applications*, 36(3), 4558-4565.

Chae, Y. M., Ho, S. H., Cho, K. W., Lee, D. H., & Ji, S. H. (2001). Data mining approach to policy analysis in a health insurance domain. *International Journal Of Medical Informatics*, 62(2-3), 103-111.

Coulter, D. M., Bate, A., Meyboom, R. H., Lindquist, M., & Edwards, I. R. (2001). Antipsychotic drugs and heart muscle disorder in international pharmacovigilance: data mining study. *Bmj*, 322(7296), 1207-1209.

Çınaroğlu, S., & Bulut, H. (2018). New initialization approaches for the k-means and particle swarm optimization based clustering algorithms. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 33(2), 413-423

Dehariya, V. K., Shrivastava, S. K., & Jain, R. C. (2010, November). Clustering of image data set using k-means and fuzzy k-means algorithms. In *2010 International Conference on Computational Intelligence and Communication Networks (pp. 386-391)*. IEEE.

Delen, D., Walker, G., & Kadam, A. (2005). Predicting breast cancer survivability: a comparison of three data mining methods. *Artificial Intelligence in Medicine*, 34(2), 113-127.

Demiralay, M., & Çamurcu, A. Y. (2005). Cure, agnes ve k-means algoritmalarındaki kümeleme yeteneklerinin karşılaştırılması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 4(8), 1-18.

Dhanachandra, N., Manglem, K., & Chanu, Y. J. (2015). Image segmentation using K-means clustering algorithm and subtractive clustering algorithm. *Procedia Computer Science*, 54, 764-771.

Doğan, B., Buldu, A., Demir, Ö., & Erol, B. (2018). Sigortacılık sektöründe müşteri ilişki yönetimi için kümeleme analizi. *Karaelmas Fen ve Mühendislik Dergisi*, 8(1), 11-18.

El-Bialy, R., Salamay, M. A., Karam, O. H., & Khalifa, M. E. (2015). Feature analysis of coronary artery heart disease data sets. *Procedia Computer Science*, 65, 459-468.

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

Erişti, H., & Tümen, V. (2012). K-means kümeleme yaklaşımı kullanarak elektrik dağıtım sistemlerindeki harmoniklerin zamansal değişimlerinin incelenmesi. ELECO Elektrik-Elektronik ve Bilgisayar Mühendisliği Sempozyumu, 29.

Feng, Y., & Hamerly, G. (2007). PG-Means: learning the number of clusters in data. In *Advances in Neural Information Processing Systems* (pp. 393-400).

Fırat, M, Dikbaş, F, Koç, A, Güngör, M . (2012). K-ortalamlar yöntemi ile yıllık yağışların sınıflandırılması ve homojen bölgelerin belirlenmesi. *Teknik Dergi*, 23 (113), 6037-6050.

Ganzert, S., Guttman, J., Kersting, K., Kuhlen, R., Putensen, C., Sydow, M., & Kramer, S. (2002). Analysis of respiratory pressure–volume curves in intensive care medicine using inductive machine learning. *Artificial Intelligence in Medicine*, 26(1-2), 69-86.

Gharib, T. F., Nassar, H., Taha, M., ve Abraham, A. (2010). An efficient algorithm for incremental mining of temporal association rules. *Data & Knowledge Engineering*, 69(8), 800-815.

Göreke, V., Uzunhisarcıklı, E., & Güven, A. (2014). Gri seviyeli eşoluşum matrisleri kullanılarak sayısal mamogram görüntüsünden doku özneliklerinin çıkarılması ve yapay sinir ağı ile kitle tespiti. *Tıp Teknolojileri Ulusal Kongresi-TıpTekno'14*.

Guo, S., Chen, J., Zhao, H., Wang, W., Yi, J., Liu, L., ... & Wang, Y. (2009). Building and evaluating an animal model for syndrome in traditional Chinese medicine in the context of unstable angina (Myocardial Ischemia) by supervised data mining approaches. *Journal of Biological Systems*, 17(04), 531-546.

Güner, Ö. Ü. S., Codal, Ö. Ü. K. S., Geçer, H. S., & Coşkun, E. (2018). Trafik kaza desenlerinin tanımlanmasında k-means kümeleme algoritmasının kullanılması: Sakarya İli Uygulaması. *İşletme Bilimi Dergisi*, 6(3), 89-105.

Güneş, S., Polat, K., & Yosunkaya, Ş. (2010). Efficient sleep stage recognition system based on EEG signal using k-means clustering based feature weighting. *Expert Systems with Applications*, 37(12), 7922-7928.

Hamerly, G., & Elkan, C. (2004). Learning the k in k-means. In *Advances in Neural Information Processing Systems* (pp. 281-288).

He, K., Wen, F., & Sun, J. (2013). K-means hashing: An affinity-preserving quantization method for learning binary compact codes. In *Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition* (pp. 2938-2945).

Hong, T. P., ve Wu, C. W. (2011). Mining rules from an incomplete dataset with a high missing rate. *Expert Systems with Applications*, 38(4), 3931-3936.

İşık, M., & Çamurcu, A. Y. (2007). K-means, k-medoids ve bulanık c-means algoritmalarının uygulamalı olarak performanslarının tespiti. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi* (6), 31-45

İşık M., & Çamurcu, A. Y. (2011). Document clustering using k-means and hyperspherical fuzzy c-means algorithms. *Marmara Fen Bilimleri Dergisi*; Cilt 22, Sayı 1 (2010); 1-18.

İşler, Y., & Narin, A. (2012). Weka yazılımında k-ortalama algoritması kullanılarak konjestif kalp yetmezliği hastalarının teşhisi. *SDU Teknik Bilimler Dergisi*, 2(2).

Jain, A. K. (2010). Data clustering: 50 years beyond k-means. *Pattern Recognition Letters*, 31(8), 651-666.

Kalogeratos, A., & Likas, A. (2012). Dip-Means: An incremental clustering method for estimating the number of clusters. In *Advances in Neural Information Processing Systems* (pp. 2393-2401).

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

KarsligEl, M. E., Yavuz, A. G., Güvensan, M. A., Hanifi, K., & Bank, H. (2017, May). Network intrusion detection using machine learning anomaly detection algorithms. In 2017 25th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.

Khaled, A., Sanjay, R., & Vineet, S. (1998). An efficient k-means clustering algorithm. In IPPS: 11th International Parallel Processing Symposium.

Khalilabad, N. D., Hassanpour, H., & Abbaszadegan, M. R. (2016). Fully automatic classification of breast cancer microarray images. *Journal of Electrical Systems and Information Technology*, 3(2), 348-359.

Khan, S. S., & Ahmad, A. (2004). Cluster center initialization algorithm for K-means clustering. *Pattern Recognition Letters*, 25(11), 1293-1302.

Kızılkaya Aydoğan, E., Gencer, C. ve Akbulut, S. (2007). Veri madenciliği teknikleri ile bir kozmetik markanın ayrılan müşteri analizi ve müşteri bölümlenmesi. *Mühendislik ve Fen Bilimleri Dergisi*, 26 (1), 43-57.

Koyuncugil, A. S. ve Özgülbaş, N. (2009). Veri madenciliği: tıp ve sağlık hizmetlerinde kullanımı ve uygulamaları. *Bilişim Teknolojileri Dergisi*, 2 (2), 21-32

Liu, Y., Li, W., & Li, Y. C. (2007, August). Network traffic classification using k-means clustering. In *Second International Multi-Symposiums on Computer and Computational Sciences (IMSCCS 2007)* (pp. 360-365). IEEE.

MacQueen, J. (1967, June). Some methods for classification and analysis of multivariate observations. In *Proceedings of The Fifth Berkeley Symposium on Mathematical Statistics and Probability* (Vol. 1, No. 14, pp. 281-297).

Muhr, M., & Granitzer, M. (2009, August). Automatic cluster number selection using a split and merge k-means approach. In *2009 20th International Workshop on Database and Expert Systems Application* (pp. 363-367). IEEE.

Münz, G., Li, S., & Carle, G. (2007, September). Traffic anomaly detection using k-means clustering. In *GI/ITG Workshop MMBnet* (pp. 13-14).

Ng, H. P., Ong, S. H., Foong, K. W. C., Goh, P. S., & Nowinski, W. L. (2006, March). Medical image segmentation using k-means clustering and improved watershed algorithm. In *2006 IEEE Southwest Symposium on Image Analysis and Interpretation* (pp. 61-65). IEEE.

Orhan, U., Hekim, M., & Ozer, M. (2011). EEG signals classification using the K-means clustering and a multilayer perceptron neural network model. *Expert Systems with Applications*, 38(10), 13475-13481.

Patrício, M., Pereira, J., Crisóstomo, J., Matafome, P., Gomes, M., Seiça, R., & Caramelo, F. (2018). Using Resistin, glucose, age and BMI to predict the presence of breast cancer. *BMC cancer*, 18(1), 29.

Peixoto, R., Ribeiro, L., Portela, F., Santos, M. F., & Rua, F. (2017). Predicting resurgery in intensive care-a data mining approach. *Procedia Computer Science*, 113, 577-584.

Pelleg, D., & Moore, A. W. (2000, June). X-Means: extending k-means with efficient estimation of the number of clusters. In *Icml* (Vol. 1, pp. 727-734).

Ravichandran, K. S., & Ananthi, B. (2009). Color skin segmentation using k-means cluster. *International Journal of Computational and Applied Mathematics*, 4(2), 153-158.

Redmond, S. J., & Heneghan, C. (2007). A method for initialising the K-means clustering algorithm using kd-trees. *Pattern Recognition Letters*, 28(8), 965-973.

Sarıman, G. (2011). Veri madenciliğinde kümeleme teknikleri üzerine bir çalışma: k-means ve k-medoids kümeleme algoritmalarının karşılaştırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(3), 192-202.

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

Singh, V. K., Tiwari, N., & Garg, S. (2011, October). Document clustering using k-means, heuristic k-means and fuzzy c-means. In 2011 International Conference on Computational Intelligence and Communication Networks (pp. 297-301). IEEE.

Singh, R. K., & Sivabalakrishnan, M. (2015). Feature selection of gene expression data for cancer classification: a review. *Procedia Computer Science*, 50, 52-57.

Sönmez, İ., & Kömüşçü, A. Ü. (2007). K-ortalamları kümeleme yöntemi ile Türkiye yağış bölgelerinin yeniden tanımlanması ve alt periyotlardaki değişimleri. *İklim Değişikliği ve Çevre*, 1(1), 38-49.

Steinley, D. (2006). K-Means Clustering: a half-century synthesis. *British Journal of Mathematical and Statistical Psychology*, 59(1), 1-34.

Tan, P. N., Steinbach, M., & Kumar, V. (2006). *Introduction to data mining*, Pearson Education. Inc., New Delhi.

Tarek, S., Elwahab, R. A., & Shoman, M. (2017). Gene expression based cancer classification. *Egyptian Informatics Journal*, 18(3), 151-159.

Taşçı, E., & Onan, A. (2016). K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. *Akademik Bilişim*.

Tatiraju, S., & Mehta, A. (2008). Image Segmentation using k-means clustering, EM and Normalized Cuts. *Department of EECS*, 1, 1-7.

Tekin, R., Kaya, Y., & Tağluk, M. E. (2011). K-Means ve ysa temelli hibrit bir model ile epileptik eeg işaretlerinin sınıflandırılması. *Elektrik Elektronik Bilgisayar Semp. Elazığ*.

Tenev, A., Markovska-Simoska, S., Kocarev, L., Pop-Jordanov, J., Müller, A., & Candrian, G. (2014). Machine learning approach for classification of ADHD adults. *International Journal of Psychophysiology*, 93(1), 162-166.

Tsai, C. Y., & Chiu, C. C. (2008). Developing a feature weight self-adjustment mechanism for a k-means clustering algorithm. *Computational Statistics & Data Analysis*, 52(10), 4658-4672.

Tucker, C. S., Kim, H. M., Barker, D. E., & Zhang, Y. (2010). A relieveff attribute weighting and x-means clustering methodology for top-down product family optimization. *Engineering Optimization*, 42(7), 593-616.

Uci Machine Learning Repository, <https://archive.ics.uci.edu/ml/datasets/Breast+Cancer+Coimbra>, (15.03.2019).

Vanitha, C. D. A., Devaraj, D., & Venkatesulu, M. (2015). Gene expression data classification using support vector machine and mutual information-based gene selection. *Procedia Computer Science*, 47, 13-21.

Yavuz, Ü. N. A. L., Ekim, U., & KÖKLÜ, M. (2011). Üniversite öğrencilerinin ortak zorunlu derslerindeki başarılarının k-means algoritması ile incelenmesi. *Engineering Sciences*, 6(1), 342-347.

Yürük, F., & Erdoğan, P. (2015). Düzce ilinin hayvansal atıklardan üretilebilecek biyogaz potansiyeli ve k-means kümeleme ile optimum tesis konumunun belirlenmesi. *İleri Teknoloji Bilimleri Dergisi*, 4(1), 47-56.

Wall, D. P., Kosmicki, J., Deluca, T. F., Harstad, E., & Fusaro, V. A. (2012). Use of machine learning to shorten observation-based screening and diagnosis of autism. *Translational Psychiatry*, 2(4), e100.

Wei, C. P., & Chiu, I. T. (2002). Turning telecommunications call details to churn prediction: a data mining approach. *Expert Systems with Applications*, 23(2), 103-112.

Wu, H., Yang, S., Huang, Z., He, J., & Wang, X. (2018). Type 2 diabetes mellitus prediction model based on data mining. *Informatics in Medicine Unlocked*, 10, 100-107.

BREAST CANCER COIMBRA DATA SET'İN K-MEANS VE X-MEANS İLE KÜMELENMESİ

Wu, M. N., Lin, C. C., & Chang, C. C. (2007, November). Brain tumor detection using color-based k-means clustering segmentation. In Third International Conference on Intelligent Information Hiding and Multimedia Signal Processing (IIH-MSP 2007) (Vol. 2, pp. 245-250). IEEE.

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZİNİTELİK SEÇİMİ

Sümeyye Çelik

Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Yönetim Bilişim Sistemleri Bölümü, Adana, Türkiye

sumeyyecelik@atu.edu.tr

1. GİRİŞ

Bilişim teknolojilerinin gelişmesi ve depolama maliyetlerinin azalmasıyla birlikte her geçen gün kaydedilen veri miktarı artmakta ve bu artış büyük veri yığınlarına sebep olmaktadır. Bu durumda ham halde duran verilerin işlenmesi ve amaçlar doğrultusunda kullanılması ihtiyacını ortaya çıkarmaktadır. Oluşan yüksek miktardaki veriler arasındaki ilişkilerin ortaya çıkarılması ve anlamlı bilgilere dönüştürülmesi bireyler ve kurumlar için oldukça önemlidir. İlişkilerin ortaya çıkarılması, teknolojinin etkin bir şekilde kullanılmasına bağlıdır. Teknolojik gelişmelerin her alanda yaygınlaşması veri madenciliği gibi birçok kavramın da kullanımına imkan tanımaktadır. Türkiye ve dünyadaki gelişmelere bakıldığında zaman kodlanan sistemler aracılığı ile her türlü bilgi çok kolay bir şekilde toplanabilmekte, toplanan veriler arasındaki ilişkiler ortaya çıkarılabilmektedir. Böylelikle manuel olarak yapılması çok zor olan birçok işlem teknoloji ile hayatımıza giren veri madenciliği, yapay zeka gibi kavramlar aracılığıyla gerçekleştirilebilmektedir.

Günümüzde teknolojinin gelişmesi ile birlikte depolanan veriler içinden anlam çıkarmak için veri madenciliği teknikleri oldukça fazla kullanılmaktadır. Kullanılan verilerin miktarı arttıkça üzerinde çalışılan yöntemlerin hızını ve verimliliğini arttırmak ise zorlaşmaktadır. Bu sebepten dolayı tüm veriler üzerinde hesaplamalar yapmak yerine örneklemeler üzerinde model çıkarımı yapmak, öznelik seçimi yapmak yada optimum değerler üzerinde çalışmak daha popüler hale gelmiş durumdadır. Bu kapsamda değerlendirildiğinde öznelik seçimi literatürde oldukça kullanılan önemli konu olmuştur. Özellikle büyük veriler ile çalışıldığı durumlarda daha da önemli bir hal almaktadır çünkü veri miktarı arttıkça çalışmanın maliyeti artmakta, hesaplamalar karmaşıklaşmakta ve işlemlerin bitirme süresi uzamaktadır. Bu süreçte elde bulunan ve kullanılacak olan özneliklerin sonucu etkileme oranı ortaya çıkarılarak etki değerleri doğru tespit edilebilir ise, sonucu etkilemeyen öznelikler çıkarılarak yapılacak olan analizde sonuçlara daha hızlı ulaşmak mümkün olacaktır (Çetişli, 2006). Bu şekilde bellekten de tasarruf sağlanacaktır (Karasulu, 2016). Aynı zamanda eldeki özneliklerin, üzerinde çalışılan konu için sonucu ne kadar etkilediği tespit edildiğinden dolayı daha anlamlı yorumlar yapılabilmekte ve önem düzeyi daha yüksek olarak görülen noktalara odaklanmayı kolaylaştırabilmektedir. Bu durum daha başarılı sonuçlar elde edilebilmesine de imkan tanıyabilmektedir (Çetişli, 2006). Veri madenciliği yöntemleri uygulanırken eldeki veriler kullanılarak anlamlar çıkarılmaya ve bir takım sonuçlar elde edilmeye çalışılmaktadır (Delen vd., 2005). Bunun doğal sonucu olarak eldeki verilerden hangilerinin bir öznelik olup olmadığı sorusunu cevabı oldukça önem arz etmektedir (Chen vd., 2010). Bu sebepten dolayı eldeki parametrelerden öznelik çıkarımı yapmak birçok veri madenciliği tekniğinde çok önemli bir paya sahiptir (Çetişli, 2006) çünkü üzerinde çalışılan konu ile alakalı olmayan özneliklerin kullanılması bir fayda sağlamayacaktır. Bu açıdan girdiler arasındaki öznelikler arasından çıkarılması durumunda sonucu değiştirmeyecek olanlar var ise onların tespit edilmesi ve çıkarılması gerekmektedir (Shi vd., 2012). Sonucu etkilemeyeceği tespit edilenler öznelikler çıkarıldıktan sonra geriye kalanlar aranan öznelikler olacaktır (Kurt ve Erdem, 2012). Tabiki belirlenen özneliklerin hepsinin önem düzeyi aynı olmayacaktır. Bazı öznelikler sonucu daha fazla etkileyecek önem düzeyine sahipken bazıları daha az önem düzeyine sahip olabilmektedir (Peng vd., 2005). Bu sebepten dolayı önem derecesi daha yüksek olan öznelikler doğru tespit edildiği zaman daha iyi sonuç elde etme performansına sahip bir öznelik kümesi oluşacaktır (Altındağ, 2013). Öznelik seçimi literatürde birçok alandaki çalışmada kullanılmış popüler bir konudur. Yapılan çalışmalardan bazıları ise şöyledir;

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

Gunal ve arkadaşları (2008) çalışmalarında örüntü tanıma, sınıflandırma, öznetelik seçimi gibi birçok veri madenciliği yöntemini kullanarak arıza tespiti üzerine çalışmışlardır.

Basmacı ve arkadaşları (2011) çalışmalarında yüz görüntüleri ile cinsiyet tanıma sistemi üzerine çalışmışlardır. Boyutları büyük olan veriler sebebi ile özelliklerin azaltılması için öznetelik seçimi gerçekleştirmiş ve sınıflandırma sonuçlarının performanslarını karşılaştırmışlardır.

Kayım ve arkadaşları (2013) çalışmalarında öznetelik seçimi, sınıflandırma gibi birçok veri madenciliği yöntemi kullanarak yüz tanıma üzerine çalışmışlardır.

Gündüz ve arkadaşları (2013) çalışmalarında kalabalık dinamiklerin tespiti için öznetelik tespiti yapmışlardır. Özneteliklerin tespitinin yanında ayrıca uygulanabilirlik durumları da incelenmişlerdir. Bunun için literatürde kabul edilen bir takım teknikleri kullanmış ve öznetelik seçiminin üzerinde durulmuşlardır. Çalışmanın sonunda ise en hızlı olduğu tespit edilen algoritmayı belirlemişlerdir.

Yağanoğlu ve arkadaşları (2014) çalışmalarında elektroansefalogram tabanlı Beyin-Bilgisayar Arayüzü sistemlerinden öznetelik seçimi için çalışmışlar ve öznetelik seçimini gerçekleştirirken birkaç yöntemi kullanarak performansları karşılaştırmışlardır. Devamında ise k-en yakın komşu yöntemini kullanarak sınıflandırma yapmışlardır.

Yoldaş ve arkadaşları (2014) çalışmalarında mamografi imgelerinden öznetelik çıkarımı yapmış ve devamında k en yakın komşu algoritması kullanılarak sınıflandırma yapmışlardır.

Gülşen ve arkadaşları (2015) çalışmalarında web kullanıcılarına uygun içeriğin sunulabilmesi için kullanıcıların web günlüğü verilerine dayanarak cinsiyetlerinin tahminlenmesi üzerine çalışmışlardır. Çalışmalarında çok fazla veri bulunduğu için öncelikle özellik seçimi gerçekleştirmişler devamında ise sınıflandırma yapmışlardır

Pençe ve Tarhan (2016) çalışmalarında öğrenim sürelerini uzatan öğrencileri tahmin etmek için çalışmışlardır. Çalışmalarında daha yüksek bir başarı sağlamak için aynı zamanda sonuca etki değeri daha yüksek olan öz niteliklerin seçilmesi işlemi de gerçekleştirmişlerdir. Çalışmalarında öğrencilere ait fakülte, sınıf cinsiyet, yaş, gibi toplam da 9 öznetelik belirlemiş, yöntem olarak ise yapay sinir ağları ve uyarlamalı sinir bulanık sınıflayıcı yöntemini kullanmışlardır.

Gümüştü ve arkadaşları (2016) çalışmalarında mikro-dizilim verilerini sınıflandırılması ve sınıflandırma başarısının artırılması için öznetelik seçimi gerçekleştirilmesi üzerine çalışmışlardır. Toplamda 11 farklı mikro-dizilim veri seti için 5 farklı öznetelik seçme algoritması denemişler ve sınıflandırma için de k en yakın komşu algoritması kullanılmışlardır.

Kaya ve Bilge (2016) çalışmalarında gen ifadesi veri seti üzerinde hızlı ve yüksek sınıflandırma başarısına sahip bir yöntem önermişlerdir. Önerilen yöntem de istatistiksel yönleri kullanmışlar ve özellik seçimi üstünde durmuşlardır.

Bektaş ve Babur (2016) çalışmalarında meme kanseri tanısı için birçok veri madenciliği yöntemini kullanarak sınıflandırma yapmışlar ve performanslarını karşılaştırmışlardır. Ayrıca başarı oranını arttırmak için genler üzerinde özellik seçimi gerçekleştirmişlerdir. Sonuçlara bakıldığı zaman yapılan özellik seçimi sonrasında başarı oranının %90 olduğu görülmüştür.

Erol ve arkadaşları (2015) çalışmalarında öznetelik seçimi üzerine çalışmışlardır. Yaptıkları çalışmada birçok özellik seçim alt kümesi oluşturarak en iyi olanı belirlemeye çalışmışlardır.

Onan ve Korukoğlu (2016) çalışmalarında dokuz farklı metin verisini sınıflandırmak için bir çalışma yapmışlardır. Çalışmada sınıflandırma yapmak için korelasyon tabanlı ve tutarlılık tabanlı gibi öznetelik seçim yöntemlerini kullanmışlardır. Sonuçlara bakıldığı zaman en yüksek başarı oranının naive bayes ile sıra arama algoritmasının birlikte kullanıldığında zaman gerçekleştiği görülmüştür.

Kaya ve arkadaşları (2017) çalışmalarında sağ ve sol gözden alınan Video-Okülografi sinyallerinden çıkarılan öznetelikleri kullanılarak diyabetik retinopati hastalığındaki evrelere göre sınıflandırılması üzerine çalışmışlardır. Ayrıca özneteliklerin seçimi için C4.5 karar ağacı algoritması

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

ve ayrık dalgacık dönüşümü yöntemini kullanılarak performans karşılaştırması da gerçekleştirmişlerdir.

Keleş ve Keleş (2018) çalışmalarında inşaat projelerinde kullanılan yapım yönetimi konusunda yapay zekanın kullanılabilirliğini ve genetik algoritma ile öznetelik seçiminin önemini incelemişlerdir. Devamında birçok veri madenciliği yöntemini kullanarak oluşturdukları veri setini sınıflandırarak performans değerlendirmesi yapmışlardır.

Çelik ve arkadaşları (2018) çalışmalarında omurga veri seti üzerinde öncelikle özneteliklerin önem düzeylerinin belirleyerek öznetelik seçimi gerçekleştirmiş devamında sınıflandırma yapmışlardır. Yöntem olarak ise uyarlamalı sinir-bulanık sınıflayıcı ve yapay sinir ağlarını kullanmışlardır. Yapılan çalışmada oldukça yüksek başarı oranları yakalamışlardır.

Akyol (2018) çalışmalarında özyinelemeli özellik seçimi metodu kullanılarak özneteliklerin önemliliğinin artırılması ve devamında sınıflandırılması üzerine çalışmıştır. Veri seti olarak meme kanseri ile ilgili veri seti yöntem olarak ise rasgele orman ve lojistik regresyon kullanmıştır. Sonuçlara bakıldığı zaman rasgele orman ile yapılan sınıflandırmada %98 oranında doğruluk yakalandığı görülmüştür.

Bilimleri (2019) çalışmalarında akıllı telefon üzerinde bulunan algılayıcıları kullanılarak toplanan verilerden öznetelik çıkarımı gerçekleştirmiş ve devamında verileri sınıflandırmıştır. Sınıflandırma için destek vektör makineleri, rastgele orman gibi birçok yöntem kullanarak performanslarını karşılaştırmıştır.

Al-Tashi ve arkadaşları (2019) çalışmalarında öznetelik seçimi için iki farklı yöntemin güçlü yönlerini kullanarak hibrit bir yöntemin oluşturulması üzerine çalışmışlardır.

Özseven (2019) çalışmasında duygu tanıma üzerine çalışmış ve öznetelik seçimi, veri ön işleme gibi yöntemler üzerinde yoğunlaşarak başarı oranını arttırmaya çalışmıştır. Sınıflandırma için üç farklı yöntem kullanmış ve performansları karşılaştırmıştır.

Ewees ve arkadaşları (2019) çalışmalarında özellik seçimi üzerine çalışmışlar ve yeni bir yöntem önermişlerdir. Önerdikleri yöntemi global optimizasyon üzerine geliştirmişlerdir. Önerdikleri yöntemin performansını değerlendirmek için ise standartlaşmış beş farklı veri setini kullanmışlardır.

Birçok alanda olduğu gibi sağlık alanında da veri madenciliğinden oldukça faydalanılmaktadır. Sağlık alanında kullanılan veriler, hastanın ilerideki tüm yaşamını etkileyebilecek kararlar alınmasına neden olabilmektedir. Bu bağlamda düşünüldüğün yapılan ve ileride yapılacak olan tüm çalışmalar büyük bir öneme sahiptir.

Bu çalışmada Venezuela Caracas'taki 'Hospital Universitario de Caracas' hastanesinde toplanan, Fernandes ve arkadaşlarının (2017) yapmış olduğu 'Transfer learning with partial observability applied to cervical cancer screening' çalışması ile UCI machine learning repository sitesinde herkese açık olarak yayınlanan Cervical cancer (Risk Factors) Data Set (<https://archive.ics.uci.edu/ml/index.php>, 15.03.2019) kullanılmış ve veri seti üzerinde özneteliklerin önem dereceleri belirlenerek öznetelik seçimi gerçekleştirilmiştir. Veri seti demografik bilgileri, alışkanlıkları ve tıbbi kayıtları ile ilgili bilgilerin yer aldığı 36 özneteliğe sahip 858 hastanın bilgilerini içermektedir. Veri seti içerisinde ki özneteliklerden 35 tanesi girdi olarak 1 tanesi ise çıktı olarak belirlenerek hazırlanmıştır. Dolayısı ile ele alınan ve önem derecesi belirlenen öznetelik sayısı 35 olmuştur. Veri seti içerisinde eksik veriler mevcuttur. Öncelikle veri seti içerisinde her bir özneteliğin ayrı ayrı aritmetik ortalaması alınarak çıkan ortalama sonuçlar ile eksik veriler tamamlanmıştır. Eksik veriler tamamlanarak tüm değerler dolu hale getirildikten sonra, tüm örnekler içi aynı değere sahip olduğu tespit edilen iki öznetelik devre dışı bırakılmıştır. Tüm örneklerde aynı değere sahip olduğu için çıkarılan özneteliklerden sonra girdi öznetelikleri 33 düşürülmüştür. Kalan 33 özneteliğin önem derecelerini belirlemek için Uyarlamalı Sinir-Bulanık Sınıflayıcı (USBS) yöntemi kullanılmıştır.

Uyarlamalı Sinir-Bulanık Sınıflayıcı'nın literatürde kullanıldığı çalışmalardan bazıları şöyledir;

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

Oral (2010) çalışmasında parmak izlerinin tanımlanması konusunda çalışmış aynı zamanda Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı gibi yöntemlerle öznetelik seçimi gerçekleştirmiştir.

Pençe ve arkadaşları (2013) çalışmalarında el yazısı karakterlerinin modellenmesi üzerine çalışmışlardır. Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı yöntemini kullanarak öznetelik seçimi gerçekleştirmişler ve sınıflandırılma yapmışlardır.

Çeşmeli ve arkadaşları (2015) öğrencilerin derslerdeki başarılarını analiz edebilmek için veri madenciliği yöntemlerini kullanarak bir çalışma yapmışlardır. Yöntem olarak öznetelik seçimi için Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı, sınıflandırma için ise yapay sinir ağlarını kullanmışlardır.

Çelik ve arkadaşları (2018) Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı'yı kullanarak insan omurgasını üzerinde öznetelik seçimi üzerine çalışmışlar ve sınıflandırma yapmışlardır.

2. VERİ MADENCİLİĞİ

Veri madenciliğinin literatürde birçok tanımı olmakla birlikte, en yaygın olan anlamına bakıldığında, elde edilen verilerin bir takım sistemsel yaklaşımlar ile analiz edilerek anlamlandırılmaya çalışıldığı süreçtir (Tenev vd.,2014). Diğer bir ifade ile normal madencilik işinin çeşitli yöntemler aracılığı ile verilere uygulanmasıdır (Akdemir, 2016). Bu şekilde veriler üzerine uygulanan yöntemler ile bilgi keşfi gerçekleştirilerek var olan bilgiler toplu halde duran veri yığınları içerisinde bulunarak keşfedilmekte ve kullanılmaktadır (Hong ve Wu, 2011).

Literatürde yapılan birkaç tanıma şunlardır:

Veri madenciliği, depolanmış veriler içinden istatistiksel veya matematiksel teknikler kullanılarak anlamlı ve yeni ilişkiler keşfetme sürecidir (Akpınar, 2000).

Veri madenciliği, depolanmış yüksek miktardaki veri yığınları içerisinde anlamlı kuralların çıkarılması işlemidir (Baykal, 2006).

Veri madenciliği, anlamlı olan fakat önceden bilinmeyen bilgilere ulaşılması ve bu bilgilerin kullanılması amacını gütmektedir (Ayık vd., 2007).

Veri madenciliği çeşitli yöntemlerle toplanan veriler üzerinde bir takım analizlerin yapılması ve gözlemlenen sonuçların değerlendirilmesi olarak ifade edilmektedir (Ferreira vd., 2012).

Veri madenciliği; bilişim sistemleri ve teknolojik araçların kullanılması ile saklanan veriler üzerinde istatistiksel teknikler ve matematiksel algoritmaların uygulanması sonucunda analizlerin gerçekleştirildiği bir süreçtir (Wei ve Chiu, 2002). Böylece alınacak olan kararlar da daha doğru ve daha hızlı olunmasına imkan tanınmaktadır (Gharib vd., 2010).

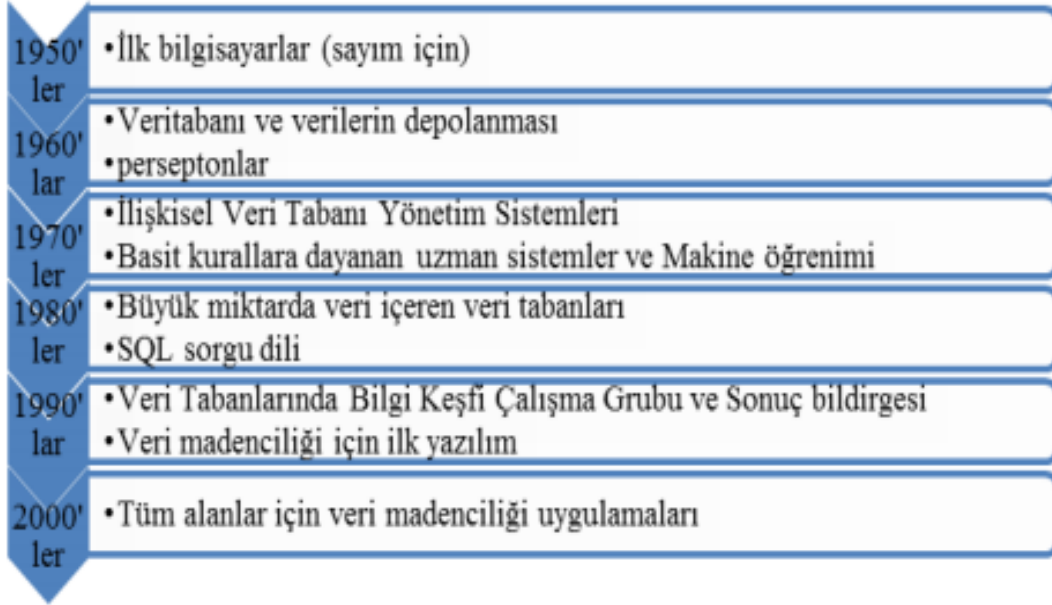
Veriler işlenmemiş halde iken bir fayda sağlamaz (Celis ve Musicant, 2002) iken bilişim sistemleriyle işlenerek bilgiye dönüştürüldüğünde anlam kazanmaktadır (Guo vd., 2009). Bu sebepten dolayı bilgiyi keşfetme süreci oldukça önemlidir. Veri madenciliği teknikleri uygulanırken iken belirli bir amaç doğrultusunda gerçekleştirilmelidir. Günümüzde teknolojik gelişmelerin bu kadar hızlı ilerlemesi ve bilgiye ulaşmanın gittikçe kolaylaşması göz önünde bulundurulduğunda, veri madenciliği tekniklerinin hayatın içinde olması çok doğal karşılanmalıdır. Bu kapsamda gün geçtikçe verilerin boyutu büyümekte ve bu büyümemenin doğal bir sonucu olarak da veri madenciliği tekniklerinin önemi de artmaktadır (Akal, 2016).

Veri madenciliği, verinin olduğu her alanda kullanılabilir bir yapıya sahip olduğundan dolayı kullanım alanı çok büyük bir yelpazeye sahiptir (Wall vd., 2012). Özellikle bilgiye ulaşma ihtiyacının gittikçe artmasıyla veri madenciliği yöntemlerinin kullanımı da gittikçe artmaktadır.

Veri madenciliğinin tarihine de bakıldığı zaman verilerin depolanması sonucunda ortaya çıktığı ve sürekli olarak geliştiği açıkça görülmektedir. Daha sonra veri tabanı yönetim sistemlerinin gelişmesi ile birlikte veri toplama platformlarının da gelişmesiyle birlikte ilerlemeye devam etmektedir. Veri madenciliğinin temeli verilerin toplanmasına ve saklanabilmesine imkan tanındığı döneme dayanmaktadır çünkü veri olmadan veri madenciliğinden bahsetmek mümkün olmayacaktır. Özellikle 1970'lerden sonra daha sistematik hale gelen veri saklama yöntemleri veri işleme konusunda birçok

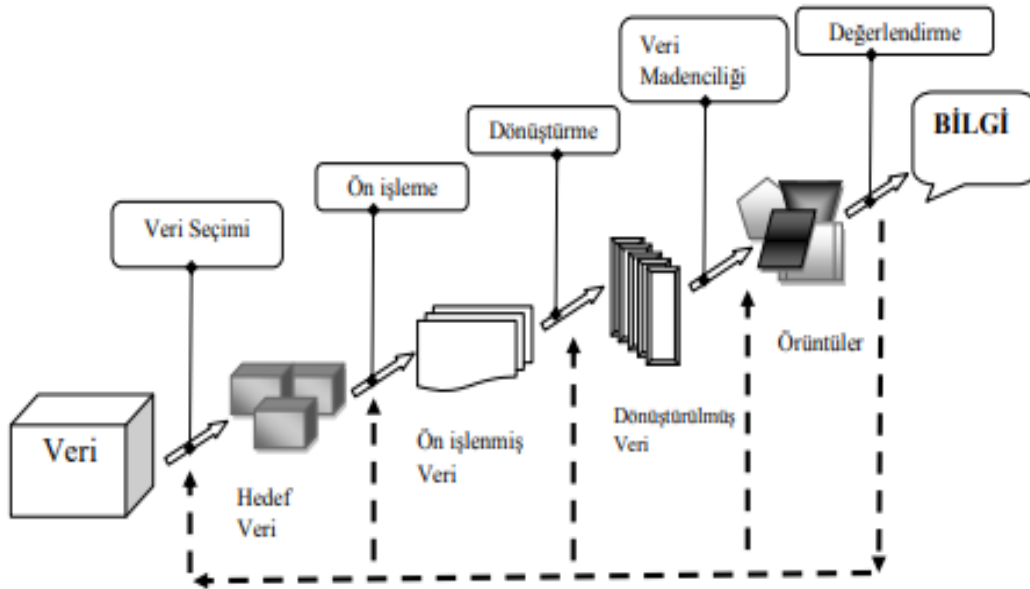
RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZİNİTELİK SEÇİMİ

imkanın oluşmasına zemin hazırlamıştır. 1980'lerden sonra ise tam anlamıyla veriler üzerinden anlam çıkarmak için yapılan çalışmalar belirginleşmiş ve bir takım modeller aktif olarak kullanılmaya başlanmıştır. Günümüzde ise artık yeni nesil entegre veri ve bilgi sistemleri geliştirilmekte ve kullanılmaya devam etmektedir (Savaş vd.,2012). Veri madenciliğini tarihsel olarak gelişim süreci Şekil 1'de görselleştirilmiştir.



Şekil 1: Veri madenciliğinin tarihsel süreci (Savaş vd.,2012).

Veri madenciliği temelinde belirli amaçlara ulaşabilmek için gerçekleştirilen aşamaların tamamıdır. Veri madenciliği sürecinin görselleştirilmiş hali Şekil 2'de verilmiştir.



Şekil 2: Veri madenciliği süreci (Savaş vd., 2012).

Şekil 2'de görüldüğü gibi veri madenciliği sürecinin başlaması için öncelikle verilere ihtiyaç vardır. Veri madenciliğinde amaç var olan veriler içerisinde belirlenen amaca yönelik uygun veri seçimi gerçekleştirilerek hedef veriye ulaşılmaktadır. Bu sebepten dolayı veri üzerinde uygulanacak veri madenciliği yönteminin daha başarılı ve doğru sonuçlar vermesi için elde edilen hedef veri üzerinde veri madenciliği yöntemlerinden olan veri ön işleme aşaması gerçekleştirilmektedir. Farklı platformlardan toplanan veriler de aynı formata dönüştürüldükten sonra veri seti üzerinde veri

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZİNİTELİK SEÇİMİ

madenciliği yöntemleri uygulanmaktadır. Kullanılan veri madenciliği yöntemleri ile veri seti içerisindeki örüntüler ortaya çıkarılmaktadır. Ortaya çıkarılan örüntüler yardımı ile yapılan değerlendirme sonucunda ise en son olarak amaca uygun bilgi ortaya çıkarılmaktadır.

Veri madenciliği Pazarlama, Devlet ve Savunma, Turizm, Banka ve Sigortacılık, Perakende ve Lojistik, İnternet, Astronomi, Tıp, Eğlence, Üretim, Telekomünikasyon, Eğitim gibi birçok alanda kullanılmaktadır. Literatür incelendiğinde veri madenciliği konusunda yapılan birçok çalışmaya rastlanmaktadır. Bu çalışmalardan bazıları şunlardır;

Yavaş (2003) çalışmasında veri madenciliği yöntemlerini kullanarak mobil kullanıcıların hareket modellerinin çıkarılması ve çıkarılan bu modellerin kullanılarak, mobil kullanıcıların daha sonraki hareketlerinin tahmin edilmesi üzerine çalışmış ve bu amaç doğrultusunda yeni bir algoritma geliştirilmiştir. Önerdiği yöntem üç aşamadan oluşmaktadır farklı tahmin yöntemleri ile karşılaştırıldığı zaman karşılaştırılan yöntemlerden daha başarılı olduğu görülmektedir.

Sıramkaya (2005) çalışmasında internet üzerinden ulaşılabilen basın-yayın kaynakları üzerinden anlamlı bilgilerin çıkarılması ile bir takım hataların önüne geçilmesi üzerine çalışmış ve bir uygulama gerçekleştirmiştir. Yöntem olarak apriori algoritması ve bulanık mantık gibi birçok veri madenciliği yöntemini kullanmıştır.

Kayaalp (2007) çalışmasında üç fazlı asenkron motordaki sargı spirleri arasında gerçekleşebilecek kısa devre ya da yalıtım bozuklukları konusunda veri madenciliği tekniklerini kullanarak bir uygulama yapmıştır.

Ata ve arkadaşları (2007) çalışmalarında kredi kartı sahiplerine yönelik müşterilerin kredi kartı kullanmayı bırakmalarını etkileyen risk faktörlerinin belirlenmesi üzerine çalışmışlardır. Yöntem olarak kümeleme, regresyon gibi veri madenciliği yöntemlerini kullanmışlar ve tahminlemelerde bulunmuşlardır. Sonuçlara bakıldığı zaman gelir, yaş ve medeni durumun kredi kartı kullanımını bırakmayı etkileyen riskler olduğu sonucuna varmışlardır.

Dener ve arkadaşları (2009) çalışmalarında veri madenciliğinde kullanılan açık kaynak kodlu ve ücretsiz olarak kullanılan RapidMiner, Weka ve R programlama uygulamalarını anlatmışlar ve örnek bir uygulama sunmuşlardır.

Ayık ve arkadaşları (2007) çalışmalarında veri madenciliği yöntemlerini kullanarak öğrencilerin mezun olduğu liseler ile kazandıkları fakülteler arasındaki ilişkiyi incelemişlerdir.

Terzi (2012) çalışmasında veri madenciliği yöntemlerini kullanarak işletmelerde yapılan hile ve usulsüzlüklerin tespit edilmesi üzerine çalışmıştır.

Terzi ve arkadaşları (2011) çalışmalarında veri madenciliği yöntemlerini kullanarak güneş ışınımının modellenmesi üzerine çalışmışlardır. Sonuçlara bakıldığında en yüksek başarının multilayer perceptron algoritması ile kurulan ve modelde üç girdinin kullanıldığı hali ile sağlandığı görülmüştür.

Şengür ve Tekin (2014) çalışmalarında veri madenciliği yöntemlerinden olan yapay sinir ağları ve karar ağaçları yöntemini kullanarak öğrencilerin mezuniyet notlarının tahminlenmesi üzerine çalışmışlardır. Sonuçlara bakıldığı zaman yapay sinir ağlarının başarı oranının daha yüksek olduğu görülmüştür.

İrmak ve arkadaşları (2012) çalışmalarında veri madenciliği yöntemlerini kullanarak hasta yoğunluklarının tahminlenmesi üzerine çalışmışlardır.

Bilen ve arkadaşları (2014) çalışmalarında lys sınavına giren öğrencilerin veri madenciliği yöntemleri ile kümelenebilmesi ve kümelerin ayrışmasında hangi test türünün daha etkili olduğunun belirlenmesi üzerine çalışmışlardır.

Savaş ve Topaloğlu (2013) çalışmalarında veri madenciliği yöntemlerini kullanarak Gsm şebekelerinin çekim güçlerinin performanslarını analiz etmişlerdir.

Keleş ve Kaya (2014) çalışmalarında bir veri madenciliği tekniği olan apriori algoritması kullanılarak duvar işçiliğinde verimliliği etkileyen faktörlerin tespit edilmesi üzerine çalışmışlardır. Çalışmalarında açık kaynak kodlu ve ücretsiz olan Weka programını kullanmışlardır.

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZİNİTELİK SEÇİMİ

Çalış ve arkadaşları (2013) çalışmalarında veri madenciliği yöntemlerinden olan metin madenciliğini kullanarak reklam epostalarının belirlenmesi üzerine çalışmışlardır. Yapılan madencilikte k en yakın komşu, destek vektör makinesi ve naive bayes kullanılmış ve yalnızca Türkçe metinler incelenmiştir.

Sezgin ve Çelik (2013) çalışmalarında veri madenciliği yöntemlerinde sıklıkla kullanılan eksik verilerin tamamlanması üzerine çalışmalar ve bu işlem için kullanılan birçok yöntemi karşılaştırarak verimliliği ölçmüşlerdir.

Özel ve Topsakal (2014) çalışmalarında veri madenciliğini kullanarak beton basınç dayanımının belirlenmesi için çalışmışlardır. Sonuçlara bakıldığı zaman oldukça yüksek başarı oranlarının yakalandığı görülmüştür.

Dolgun ve Ersel (2014) çalışmalarında veri madenciliği yöntemlerinden olan destek vektör makineleri, karar ağaçları ve lojistik regresyon gibi birçok algoritmayı kullanarak doğrudan pazarlama kampanyalarının nasıl yönlendirilebileceği konusunda çalışmışlardır. Çalışma alanı olarak belirledikleri sektör bankacılık olmuştur.

Göker ve Tekedere (2017) çalışmalarında internet ortamında FATİH projesine yönelik yapılan yorumların otomatik olarak belirlenmesi üzerine çalışmışlar ve bunu gerçekleştirebilmek için veri madenciliği yöntemlerinden olan metin madenciliğini kullanmışlardır. Sonuçlara bakıldığı zaman %88 oranında başarıya ulaşıldığı görülmüştür.

Pehlivanoğlu ve Nevcihan (2015) çalışmalarında öğrencilerin temel özellikleriyle, sosyal ağlar üzerindeki faaliyet durumları arasındaki ilişkiyi tespit etmek için veri madenciliğini kullanarak Kocaeli özelinde bir çalışma yapmışlardır. Yöntem olarak apriori algoritmasını program olarak ise açık kaynak kodlu Weka'yı kullanmışlardır.

Kılınç ve arkadaşları (2016) çalışmalarında veri madenciliği yöntemlerinden olan metin madenciliğini kullanarak akademik yayınların otomatik sınıflandırılması üzerine çalışmışlardır. Örnek makalelerin temin edilmesi ve veri setlerinin oluşturulması için Research Gate internet sitesini kullanmışlardır. Sonuçlara bakıldığı zaman %96 oranında başarıya ulaştıkları görülmektedir.

2.1. Sağlık Alanında Veri Madenciliği Kullanımı

Hastalık teşhisi konulurken ve tedavi yöntemleri uygulanırken vakanın ciddiyet durumu arttıkça verilecek kararlar ve uygulanacak işlemler için zaman kaybına olan tahammül de azalmaktadır çünkü geçen her zaman durumun ciddiyetini arttırmaktadır. Bu gibi durumlarda sürecin hızlandırılması ve zaman kaybının önüne geçilmesi gerekmektedir. Bu kapsamda değerlendirildiğinde kısa zamanda doğru kararlar verilebilmesi birçok alanda olduğu gibi sağlık alanında da çok büyük bir öneme sahiptir. Bu sebeplerden dolayı sağlık alanında veri madenciliği yöntemlerinden oldukça faydalanılmaktadır. (Reddy vd., 2012). Bu konuda literatür de sayısız araştırmaya rastlanmaktadır.

Örneğin Berthonnaud ve arkadaşları (2005) çalışmalarında yüz altmış bireyin röntgen verilerini kullanarak şekil ve yön öznelikleri ile omurga dengesinin analizi gerçekleştirmişlerdir. Ayrıca omurganın şekil ve yöneliminden elde edilen indeksleri kullanarak insan gövdesinin dengesini karakterize etmeye çalışılmışlardır.

Doğan ve Türkoğlu (2008) çalışmalarında ile demir eksikliği anemisi teşhisinde, hekime yardımcı olacak bir karar destek sistemi oluşturulması için veri madenciliği yöntemlerinin kullanılması üzerine çalışmışlardır. Yöntem olarak karar ağaçlarını kullanmışlardır.

Da Rocha Neto ve arkadaşları (2011) çalışmalarında bir takım patolojilerin teşhisi konusundaki kararın alınması için çeşitli teknolojik yöntemleri uygulamışlardır. Kullandıkları algoritmaların performanslarını değerlendirmişler ve en yüksek performansa sahip algoritma tespit etmişlerdir.

Chae ve arkadaşları (2001) çalışmalarında logistic regression, chaid ve c 5.0 gibi bir çok tahmin modelini kullanarak belirledikleri öznelikler yardımı ile bireylerin yüksek tansiyona sahip olup olmadığını tahminlemişlerdir. Kullandıkları verilerini Koredeki sağlık sigortası kurumundan

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

temin etmişler ve çalışmanın sonunda yüksek tansiyona etki değeri fazla ve az olan öznetelikleri tespit etmişlerdir.

Demircioğlu ve Bilge (2015) çalışmalarında çok fazla bilgi üretildiğinin ve bu bilgilerin doğru şekilde analiz edilmesi gerekliliğinin vurgusunu yapmış ve veri madenciliği yöntemlerini kullanarak kanser üzerine yapılan çalışmaları değerlendirmişlerdir. Devamında ise genler üzerinde özneteliklerin belirlenmesi konusunda uygulama yapmışlardır. Öncelikle iki farklı yöntem kullanarak öznetelik seçimi gerçekleştirmişler ve belirlenen öznetelikler ile verileri sınıflandırmışlardır. Çalışmalarının sonuçlarda ise yöntemleri karşılaştırarak bitirmişlerdir.

İşler ve Narin (2012) çalışmalarında kalp yetmezliği hastalığına sahip bireylerin tahminlenmesi ve küme sayılarının belirlenmesi üzerine çalışmışlardır. Sonuçlara bakıldığı zaman en yüksek başarın küme sayısının dört olarak seçildiğinde sağlandığı görülmektedir.

Ganzert ve arkadaşları (2002) çalışmalarında makine öğrenmesi ve veri madenciliği yöntemlerinin kullanarak solunum basıncı hacim eğrilerini analiz etmek için çalışmışlardır. Uygulama detayına bakıldığı zaman C5.0 algoritmasını kullanmışlar ve elde ettikleri eğrilere dayanarak umut vadeden sonuçlara ulaşmışlardır. Çalışmalarının sonunda ise daha çok araştırma yapılması gerektiğini vurgulamışlardır.

Coulter ve arkadaşları (2007) çalışmalarında veri madenciliğini kullanarak uluslararası antipsikotik ilaçlar ve kalp kası bozukluğu üzerine çalışmışlardır. Yöntem olarak bayesian algoritmasını kullanmışlardır. Sonuçlara bakıldığı zaman bazı antipsikotik ilaçların kardiyomiyopati ve miyokardit ile ilişkili olduğu görülmüştür.

Danacı ve arkadaşları (2010) çalışmalarında kanser çeşitlerinden biri olan meme kanseri hakkında kısa bilgi verilmişler ve devamında örüntü tanıma programı yardımı ile elde edilen verileri Weka programı kullanılarak meme kanseri hücrelerinin tahmin edilmesi üzerine çalışmışlardır.

Göreke ve arkadaşları (2014) çalışmalarında meme kanserini tahmin etmeye yardımcı olabilmek için bilgisayar sistemleri kullanılmışlardır. Bu amaç doğrultusunda teşhiste kullanılabilecek öznetelikleri belirlemeye çalışılmışlardır. Belirlenen özneteliklerle testler gerçekleştirmişler ve yapılan test aşamasında yüksek derecede başarı elde etmişlerdir.

Wu ve arkadaşları (2018) çalışmalarında şeker hastalığını tahmin etmek için veri madenciliği yöntemlerine dayalı yeni bir model önermişlerdir. Amaçları tahmin modelini birden fazla veri kümesine uyarlamak olmuştur. Uygulamalarında öncelikle veri ön işleme aşamalarını gerçekleştirmişler ve sonrasında yöntem olarak ise k-means ve lojistik regresyon algoritması kullanılmışlardır. Sonuçlara bakıldığı zaman önerilen modelin başarı oranının diğer yöntemlerle karşılaştırıldığı zaman %3.04 daha yüksek olduğu görülmektedir.

Strilka ve arkadaşları (2017) çalışmalarında aralıklı gastrik beslemeleri ve sürekli post-pilorik beslemelerini karşılaştıran matematiksel bir model kullanılmışlardır.

Peng ve arkadaşları (2018) çalışmalarında hastalık-10'uncu revizyon kodlarının idari sağlık verilerine ilişkin durumunu ortaya konulmuşlardır. Sonuç olarak ise sunulan ilişkilendirme kurallarının, veri kalitesi değerlendirmesi açısından gelecekteki araştırmalara referans olabileceğini vurgulanmışlardır.

Khalilabad ve arkadaşları (2016) çalışmalarında meme kanseri tipinin belirlenmesi için bir uygulamam yapmışlardır. Yapılan çalışmada genlerin yerini belirlemek için görüntü işleme tekniklerini kullanmışlardır. Yöntem olarak karar ağacını kullanmışlar ve meme kanseri tipini % 95.23'lük bir doğrulukta tespit etmişlerdir.

Lewis ve arkadaşları (2003) çalışmalarında mRNA'nın 5 bölgesinde korunmuş eşleme ile mRNA'ları tanımlamışlardır ve kalitesini değerlendirmişlerdir. Sonuçlara bakıldığı zaman korunmuş omurgalı mRNA'lar için dört yüzden fazla düzenleyici hedef geni önermişlerdir.

Singh ve Sivabalakrishnan (2015) çalışmalarında kanser araştırmasının, tıp alanındaki en önemli araştırma konularından bir tanesi olduğu vurgusunu yapmışlardır ve farklı tümör tiplerinin kesin olarak tahmin edilmesinin zorluklarından bahsedilmişleridir. Bu kapsamda başarıyı arttırmak

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

amacıyla veri madenciliği algoritmalarının kullanımının gerekliliği vurgulamışlardır. Çalışmalarında aynı zamanda farklı özellik seçimi algoritmaları ile makine öğrenimi tabanlı veri analizinde son gelişmeleri de değerlendirmişlerdir.

Tarek ve arkadaşları (2017) çalışmalarında gen ekspresyon profilleri için etkili bir analiz gerçekleştirilmesi adına makine öğrenme algoritmaları, veri madenciliği yöntemleri ve istatistiksel yöntemleri kullanarak kanser sınıflandırması için uygulama yapmışlardır. Kanser sınıflaması için gen ekspresyon profillerine dayanan yeni bir topluluk sistemi sunmuşlardır. Sonuçlara bakıldığında oluşturulan yeni sistemin öncekilerden daha hızlı olduğu ve daha fazla kanser türünü kapsadığı görülmüştür.

Vanitha ve arkadaşları (2015) çalışmalarında destek vektör makinesini kullanılarak gen sınıflandırması için etkili bir yöntem sunmuşlardır. Yöntemin başarısını değerlendirmek için tek noktali çapraz doğrulama yöntemini kullanılmışlar veri seti olarak ise iki kanser mikro dizinini kullanılmıştır. Çalışmanın sonuçlarına bakıldığı zaman diğer yaklaşımlarla göre sınıflandırma doğruluğunun arttığı ve girdilerin boyutunun azalttığı görülmektedir.

Peixoto ve arkadaşları (2017) çalışmalarında yoğun bakım ünitelerinin performansını iyileştirmek ve sağlık profesyonellerine yardımcı olmak için çalışmışlardır. Bu amaç doğrultusunda hastaneden elde edilen veri seti üzerinde bir takım veri madenciliği yöntemleri uygulamışlardır. Sonuçlara bakıldığı zaman yapılan tahminlemedeki başarı oranının %90 olduğu görülmektedir.

Mohebian ve arkadaşları (2017) çalışmalarında meme kanserinin nüksetme durumunun tahmin edilmesi üzerine çalışmışlardır. Zaman periyodu olarak beş yıllık süreyi baz almışlar ve bir yöntem sunmuşlardır. Uygulanama kısmında parçacık sürü optimizasyonu, çok katmanlı yapay sinir ağı ve karar ağacı yöntemlerini kullanılmışlardır. Verileri beş yüz yetmiş dokuz meme kanseri hastasından toplanmışlar ve klinikopatolojik özelliklerini incelenmiştir. Aynı zamanda istatistiksel yöntemler de kullanarak ayırt edici özellikleri belirlemişlerdir.

3. ARAŞTIRMADA KULLANILAN YÖNTEM

Araştırmada Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı yöntemi kullanılmıştır.


3.1. Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı

Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı temelde içerisinde iki işlemi barındıran bir yöntemdir. Bu yöntem kullanılarak özneteliklerin önem derecesi belirlenmekte ve aynı zamanda ikinci aşama olarak sınıflandırma işlemi gerçekleştirilmektedir. (Pençe vd, 2013). Bu yöntem ile bulanık çıkarsama kullanılarak özneteliklerin önem dereceleri belirlendiği için veri seti içerisinde de önem derecesi yüksek olan öznetelikler seçilirken, önem derecesinin sıfır olarak görüldüğü öznetelikler devre dışı bırakılmaktadır. (Çetişli, 2006). Bu açıdan bakıldığı zaman önemli görülmeyen öznetelikler çıkarıldığı için bellekten de tasarruf sağlanmaktadır (Çelik vd., 2018). Böyle bu durum daha sonrasında yapılacak işlemler için hızın artmasının yanında maliyetlerin de azalmasına yardımcı olmaktadır (Çetişli, 2006). Sonuç itibari ile her hangi bir yöntem ile yapılan işlemlerde bazı özneteliklerin çıkarılması durumunda başarısı oranında bir azalma görülüyor ise o özneteliklerin kullanılmasına gerek yoktur yorumunu yapmak mümkündür (Huang ve Chow, 2005). Gerçek hayat problemlerine de bakıldığı zaman çözüme gidilirken oluşturulan alternatiflerin etki düzeyi farklı olabilmekte ve bazı alternatiflerin çözüm yolunda hiçbir etkisinin olmadığı görülmektedir. Bu bağlamda her ne kadar çözüme ulaşmak kıymetli olsa da çözüme daha hızlı ulaşmak daha kıymetlidir. (Liu vd., 2005). Bu açıdan bakıldığı zaman özneteliklerin doğru tespit edilmesi gerçek hayat problemlerinin çözümüne daha yakın bir çözüm yolu oluşturmaktadır. Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı, öznetelikleri belirlerken sadece “vardır” ya da “yoktur” şeklinde net ifadeler kullanmak yerine her birinin tek tek önem düzeyini ortaya koymaktadır (Fırat, 2008) ve bu çıkarımları yapmak için bulanık kuralları kullanmaktadır. Öznetelikler, bulanık kurallar ile belirlenirken aşamalı bir süreç izlenmekte derecelendirme mantığı ile ilerlenmektedir (Çağlar vd., 2010). Böylece bulanıklık, sistemi “evet” ya da “hayır” gibi kesin cevaplardan kurtarmaktadır (Koçyiğit ve Korürek, 2010). Yani bir öznetelik için sonuç “var” ya da “yok” şeklinde değil "az var", "var" yada "çok var" gibi dereceli

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

olacak şekilde nitelendirilmektedir. Bu şekilde önem dereceleri belirlenen özniteliklerin insan çıkarsamalarına benzerliği arttırılmış olmaktadır (Cetişli ve Kalkan, 2011).

A dilsel terimine uygulanan dilsel kuvvetlerin değişik p değerleri için yorumları Şekil 3' de gösterilmiştir.




Şekil 323: A dilsel terimine uygulanan dilsel kuvvetlerin değişik p değerleri için yorumları

Şekil 3'de dilsel kuvvetlerin farklı p değerleri (- 2, -0.5, 0, 0.5, 1, 2) için kuvvetlendirilmiş şeklinin a dilsel terimine uygulanması gösterilmiştir. Şekil 3' de, p 'nin negatif değer olması durumunda ($p < 0$) üyelik fonksiyonunun yönünün değiştiği görülmektedir. Durum böyle olunca üyelik değeri 1'den büyük olmaktadır ama üyelik değerinin $[0 + 1]$ aralığının dışında olması çok da istenilen bir durum değildir. Bunun sebebi aralık $[0 + 1]$ 'in dışına çıktığı zaman kümelerin bulanıklık özelliğini kaybetmesidir. Bu açıdan Kümlerin bulanıklığını kaybetmemesi adına p değeri 0 veya sıfırdan büyük olmalıdır. P değeri hesaplandığı zaman aslında öznitelik önem derecesinde ortaya çıkarılmış olmaktadır çünkü öznitelik önem derecesi hesaplanan bu p değerine bakılarak oluşturulmaktadır. P değeri 1'e ne kadar yakın çıkarsa önem düzeyi o kadar fazla, 1 den ne kadar çok uzaklaşıp 0 ne kadar yaklaşırsa önem düzeyi o kadar düşüktür şeklinde yorumlanmaktadır. P değerinin sıfır çıkması durumunda ise o öznitelik hiç önemi yoktur denilebilmektedir. (Cetişli ve Kalkan, 2011).

İki-girişli, bir-çıkışlı bir bulanık kuralın normal ve dilsel kuvvetli halinin mamdani çıkarım sistemindeki sonuçları Şekil 4'de gösterilmiştir.


RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ



Şekil 424: İki-girişli, bir-çıkışlı bir bulanık kuralın normal ve dilsel kuvvetli halinin Mamdani çıkarım sistemindeki sonuçları (Çetişli, 2006).

Şekil 4'de, x_1 ve x_2 giriş değişkenleri için, B kümesinin yüksek bir dereceyle seçilmesi istenir ise, A_2 bulanık kümesinin bu duruma engel olduğu görülmektedir. Bu durumda A_2 devre dışı bırakılmalı ve yalnızca A_1 kullanılmalıdır. Dilsel kuvvet 0 olduğu zaman önem düzeyinin hiç olmadığı ortaya konulduğundan dolayı A_2 kümesini devre dışı bırakmak için dilsel kuvvet 0 olarak kullanılmaktadır. Böylece önem düzeyi 0 olan x_2 uzayı kuraldan çıkarılmış olmakta ve B kümesinin seçilme derecesi artmaktadır (Çetişli, 2006).

Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı ile özneteliklerin önem düzeyi belirlendikten sonra sınıflandırma işlemi gerçekleştirilebilmektedir. Sınıflandırma işlemi için yapay sinir ağları kullanılmaktadır. Yapay sinir ağları insan beynin çalışma yapısını matematiksel olarak modellenerek algoritmaya uygulanması ile ortaya çıkarılmış bir veri madenciliği yöntemidir. Oldukça geniş kullanım alanına sahip yapay sinir ağları katmanlar halinde oluşturulur ve belirlenen katmanlar da çözümlenmek istenen probleme göre farklılık gösterebilmektedir. Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı'nın sınıflandırma aşamasında Şekil 5'de gösterildiği şekli ile kullanılmaktadır.



Şekil 525: YSA kullanım şekli (Çetişli, 2006).

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

Şekil 5’de görüldüğü gibi Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı giriş, üyelik, kuvvet, bulanıklaştırma, doğrulama, normalizasyon ve çıkış katmanı şeklinde birçok katmandan oluşmaktadır.

ARAŞTIRMADA KULLANILAN VERİ SETİ

Bu çalışmada Venezuela Caracas'taki 'Hospital Universitario de Caracas' hastanesinde toplanan, Fernandes ve arkadaşlarının (2017) yapmış olduğu ‘Transfer learning with partial observability applied to cervical cancer screening’ çalışması ile UCI machine learning repository sitesinde herkese açık olarak yayımlanan Cervical cancer (Risk Factors) Data Set kullanılmıştır.

Veri seti demografik bilgileri, alışkanlıkları ve tıbbi kayıtları ile ilgili bilgilerin yer aldığı 36 özneteliğe sahip 858 hastanın bilgilerini içermektedir. Veri setindeki öznetelikler kaynağında verilen isimleri ile Tablo 1’de verilmiştir.

Tablo 1: Özneteliklerin özellikleri

Öznetelik numarası	Öznetelik türü ve adı
1	(int) Age
2	(int) Number of sexual partners
3	(int) First sexual intercourse (age)
4	(int) Num of pregnancies
5	(bool) Smokes
6	(bool) Smokes (years)
7	(bool) Smokes (packs/year)
8	(bool) Hormonal Contraceptives
9	(int) Hormonal Contraceptives (years)
10	(bool) IUD
11	(int) IUD (years)
12	(bool) STDs
13	(int) STDs (number)
14	(bool) STDs:condylomatosis
15	(bool) STDs:cervical condylomatosis
16	(bool) STDs:vaginal condylomatosis
17	(bool) STDs:vulvo-perineal condylomatosis
18	(bool) STDs:syphilis
19	(bool) STDs:pelvic inflammatory disease
20	(bool) STDs:genital herpes
21	(bool) STDs:molluscum contagiosum
22	(bool) STDs:AIDS
23	(bool) STDs:HIV
24	(bool) STDs:Hepatitis B
25	(bool) STDs:HPV
26	(int) STDs: Number of diagnosis
27	(int) STDs: Time since first diagnosis
28	(int) STDs: Time since last diagnosis
29	(bool) Dx:Cancer
30	(bool) Dx:CIN
31	(bool) Dx:HPV
32	(bool) Dx
33	(bool) Hinselmann: target variable
34	(bool) Schiller: target variable
35	(bool) Cytology: target variable
36	(bool) Biopsy: target variable

Veri seti içerisinde ki özneteliklerden ilk 35 öznetelik girdi olarak 36. Öznetelik ise çıktı olarak belirlenmiştir. Dolayısı ile ele alınan ve önem derecesi belirlenen öznetelikler ilk 35 öznetelik

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

olmuştur. Veri seti içerisinde eksik veriler mevcuttur. Öncelikle veri seti içerisinde her bir özneteliğin ayrı ayrı aritmetik ortalaması alınarak çıkan ortalama sonuçlar ile eksik veriler tamamlanmıştır. Eksik veriler tamamlanarak tüm değerler dolu hale getirildikten sonra tüm örnekler için aynı değere sahip olduğu tespit edilen 15 numaralı STDs:cervical condylomatosis ve 22 numaralı STDs:AIDS iki öznetelik devre dışı bırakılmıştır. Tüm örneklerde aynı değere sahip olduğu için çıkarılan STDs:cervical condylomatosis ve STDs:AIDS özneteliklerinden sonra girdi öznetelikleri 33 düşürülmüştür. Kalan 33 özneteliğin önem derecelerini belirlemek için Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı yöntemi kullanılmıştır.

4. BULGULAR VE DEĞERLENDİRME

Bu çalışmada demografik bilgileri, alışkanlıkları ve tıbbi kayıtları ile ilgili bilgilerin yer aldığı 36 özneteliğe sahip 858 hastanın bilgilerini içeren ve kanser risklerinin belirlenmesi için bilimsel bir araştırma aracılığı ile toplanarak UCI machine learning repository sitesinde herkese açık olarak yayınlanan Cervical cancer (Risk Factors) veri seti kullanılarak veri setindeki özneteliklerin önem dereceleri belirlenmiş ve öznetelik seçimi gerçekleştirilmiştir. Veri seti içerisinde eksik veriler bulunmaktadır. Yapılan analizlerin daha doğru ve etkili sonuçlar verebilmesi için öncelikle veri ön işleme aşaması gerçekleştirilerek eksik veriler tamamlanmıştır. Eksik verilerin tamamlanması için aritmetik ortalama yöntemi kullanılmıştır. Yani her bir özneteliğin, tüm örnekler için olan ortalaması alınmış ve her öznetelik için eksik olan veriler belirlenen değer ile doldurulmuştur. Yöntem olarak Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı kullanılmıştır. Şekil 6'da gösterilen her bir çizgi Tablo 2'de gösterildiği listeden 36 numaralı öznetelik çıktı parametresi olarak kullanıldığı için, 15 numaralı STDs:cervical condylomatosis ve 22 numaralı STDs:AIDS iki öznetelik de eksik veriler tamamlandıktan sonra tüm örneklerde aynı değere sahip olduğundan dolayı etki değerleri olmadığı için devre dışı bırakıldıktan sonra Tablo 2'de verilen sırayla kullanılmıştır.

Tablo 2: Kullanılan öznetelik sırası

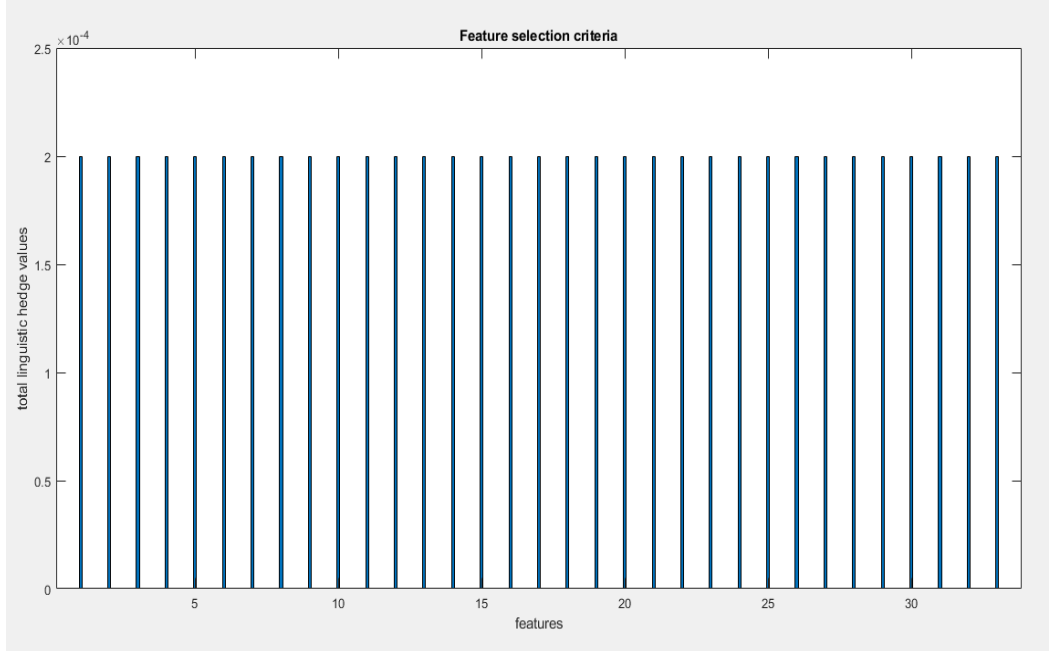
Öznetelik numarası	Öznetelik adı
1	Age
2	Number of sexual partners
3	First sexual intercourse (age)
4	Num of pregnancies
5	Smokes
6	Smokes (years)
7	Smokes (packs/year)
8	Hormonal Contraceptives
9	Hormonal Contraceptives (years)
10	IUD
11	IUD (years)
12	STDs
13	STDs (number)
14	STDs:condylomatosis
15	STDs:vaginal condylomatosis
16	STDs:vulvo-perineal condylomatosis
17	STDs:syphilis
18	STDs:pelvic inflammatory disease
19	STDs:genital herpes
20	STDs:molluscum contagiosum
21	STDs:HIV
22	STDs:Hepatitis B
23	STDs:HPV
24	STDs: Number of diagnosis
25	STDs: Time since first diagnosis
26	STDs: Time since last diagnosis

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

Tablo 2'nin devamı

Öznitelik numarası	Öznitelik adı
27	Dx:Cancer
28	Dx:CIN
29	Dx:HPV
30	Dx
31	Hinselmann: target variable
32	Schiller: target variable
33	Cytology: target variable

Öznitelik çıkarımı sonucu özniteliklerin belirlenen önem düzeyleri Şekil 6'de verilmiştir.



Şekil 6: Öznitelik seçim kriteri

Numaralandırma her bir öznitelik için gerçekleştirilmiştir ama kullanılan öznitelik sayısı fazla olduğu için ekranda gösterilirken verilen numaralar beşin katları şeklinde görselleştirilmiştir. Sonuçlara bakıldığı zaman Şekil 6'da görüldüğü gibi tüm özniteliklerin aynı şekilde yüksek önem düzeyine sahip olduğu tespit edilmiştir. Bu sonuç kanser riskini tahmin etmek için toplanan veriler ile alakalı olarak elde edilen özniteliklerin tamamının risk düzeyini ölçmek için gerekli olduğunu göstermektedir. Bu sonuçlara bakılarak ayrıca kanser riskini değerlendirmek için orijinal isimleri ile Age, Number of sexual partners, First sexual intercourse (age), Num of pregnancies, Smokes, Smokes (years), Smokes (packs/year), Hormonal Contraceptives, Hormonal Contraceptives (years), IUD, IUD (years), STDs, STDs (number), STDs:condylomatosis, STDs:vaginal condylomatosis, STDs:vulvo-perineal condylomatosis, STDs:syphilis, STDs:pelvic inflammatory disease, STDs:genital herpes, STDs:molluscum contagiosum, STDs:HIV, STDs:Hepatitis B, STDs:HPV, STDs: Number of diagnosis, STDs: Time since first diagnosis, STDs: Time since last diagnosis, Dx:Cancer, Dx:CIN, Dx:HPV, Dx, Hinselmann: target variable, Schiller: target variable, Cytology: target variable değişkenlerinin tamamı risk düzeyinin belirlemek için etkidir yorumunu yapmak mümkün olacaktır.

5. SONUÇ

Bu çalışmada rahim ağzı kanseri veri seti üzerinde özniteliklerin önem dereceleri belirlenerek öznitelik seçimi gerçekleştirilmiştir. Böylelikle gerekli görülmeyen özniteliklerin dışarda bırakılarak önem düzeyi yüksek olanların belirlenmesine imkan tanınmıştır. Yöntem Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı kullanılmıştır. Kullanılan veri seti daha öncede kullanılmış ve farklı bir yöntemle analiz edilmiştir. Bu çalışmada ise önemli özniteliklerin tespiti üstünde durulmuştur. Bu sebepten

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

dolayı literatürde öznetelik seçiminde sıkça kullanılan Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı yöntemi tercih edilmiştir. Normal hayat problemlerinde de sonucu etkileme durumlarına bakıldığı zaman, tüm özneteliklerin sonucu etkileme oranının aynı olmadığı görülmektedir. Bu açıdan bakıldığı zaman doğru öznetelik seçimi önemlidir ve doğru noktaya odaklanmaya yardımcı olabilmektedir. Bu çalışmada da önem derecesi yüksek olan öznetelikler Dilsel Kuvvetli Sinir-Bulanık Sınıflayıcı yöntemi ile tespit belirlenmiştir. Belirlenen öznetelikler Age, Number of sexual partners, First sexual intercourse (age), Num of pregnancies, Smokes, Smokes (years), Smokes (packs/year), Hormonal Contraceptives, Hormonal Contraceptives (years), IUD, IUD (years), STDs, STDs (number), STDs:condylomatosis, STDs:vaginal condylomatosis, STDs:vulvo-perineal condylomatosis, STDs:syphilis, STDs:pelvic inflammatory disease, STDs:genital herpes, STDs:molluscum contagiosum, STDs:HIV, STDs:Hepatitis B, STDs:HPV, STDs: Number of diagnosis, STDs: Time since first diagnosis, STDs: Time since last diagnosis, Dx:Cancer, Dx:CIN, Dx:HPV, Dx, Hinselmann: target variable, Schiller: target variable, Cytology: target variable olmuştur.

Sonuç olarak veri madenciliği süreci kullanılarak var olan veriden işimize yarayacak olan bilgiyi elde etmek amaçlanmaktadır. Dolayısıyla öznetelik seçimi de var olan öznetelikler arasında sonucu etkileme oranı yüksek olanları seçmede kullanıldığı için veri madenciliği süreci içerisinde önemli bir aşamayı oluşturmaktadır. Bu sebepten dolayı bu çalışmada da öznetelik seçimi gerçekleştirilmiştir.

Bu çalışmada yalnızca öznetelik tespiti gerçekleştirilmiş, sınıflandırma ya da kümeleme gibi işlemler yapılmamıştır. Gelecek çalışmalarda ise belirlenen öznetelikler kullanılarak sınıflandırma ya da kümeleme gibi yöntemler kullanılarak tahminlemeler yapılabilecektir.

6. KAYNAKÇA

Akal, Ş. (2016). Sağlık alanında akıllı teknolojilerin kullanımı için bir uygulama önerisi. Uluslararası Yönetim Bilişim Sistemleri Konferansı, (3), 291-297.

Akdemir, Ç. (2016). Hilenin Veri Madenciliği İle Ortaya Çıkarılması ve Perakende Sektöründe Bir Uygulama. Doktora tezi. İstanbul: Marmara üniversitesi sosyal bilimler enstitüsü.

Akpınar, H. (2000). Veri tabanlarında bilgi keşfi ve veri madenciliği. İÜ İşletme Fakültesi Dergisi, 29(1), 1-22.

Akyol, K. (2018). Meme kanseri tanısı için özneteliklerin öneminin değerlendirilmesi üzerine bir çalışma. Academic Platform Journal of Engineering and Science, 6(2), 109-115.

Al-Tashi, Q., Kadir, S. J. A., Rais, H. M., Mirjalili, S., & Alhussian, H. (2019). Binary Optimization Using Hybrid Grey Wolf Optimization for Feature Selection. IEEE Access, 7, 39496-39508.

Ata, N., Özkök, E. & Karabey, U. (2008), Survival Data Mining: An Application To Credit Card Holders. Sigma Mühendislik ve Fen Bilimleri Dergisi, Cilt 26, No 1, 33-42.

Altındağ, O. (2013). Kanser sınıflandırmada mikrona ve mrna anlatım bilgilerinin entegrasyonu. Yayınlanmamış yüksek lisans tezi, Başkent Üniversitesi, Ankara.

Ayık, Y. Z., Özdemir, A., & Yavuz, U. (2007). Lise türü ve lise mezuniyet başarısının, kazanılan fakülte ile ilişkisinin veri madenciliği tekniği ile analizi. Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 10(2), 441-454.

Basmacı, E. S., Kaymakcioğlu, U., & Kurt, Z. (2011, April). Comparison of feature extraction and feature selection approaches to decide whether a face image belongs to a male or a female. In 2011 IEEE 19th Signal Processing and Communications Applications Conference (SIU) (pp. 522-525).

Baykal, A. (2006). Veri madenciliği uygulama alanları. Dicle Üniversitesi Ziya Gökalp Eğitim Fakültesi Dergisi, 7, 96.

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

Bektaş, B., & Babur, S. (2016, October). Machine learning based performance development for diagnosis of breast cancer. In 2016 Medical Technologies National Congress (TIPTEKNO) (pp. 1-4). IEEE.

Berthonnaud, E., Dimnet, J., Roussouly, P., & Labelle, H. (2005). Analysis of the sagittal balance of the spine and pelvis using shape and orientation parameters. *Clinical Spine Surgery*, 18(1), 40-47.

Bilen, Ö., Hotaman, D., Aşkın, Ö. E., & Büyüklü, A. H. (2014). LYS başarılarına göre okul performanslarının eğitsel veri madenciliği teknikleriyle incelenmesi: 2011 İstanbul örneği. *Eğitim ve Bilim*, 39(172).

Bilimleri, M. (2019). Ulaşım türü tanımda enerji kısıtlı cihazlar için ayırt edici özellikler. *Journal of Engineering Sciences*, 7(1), 90-102.

Celis, S., & Musicant, D. R. (2002). Weka-parallel: machine learning in parallel. In Carleton College, CS TR.

Cetişli, B., & Kalkan, H. (2011, April). Classification of multispectral satellite images by using adaptive neuro-fuzzy classifier with linguistic hedges. In 2011 IEEE 19th Signal Processing and Communications Applications Conference (SIU)(pp. 50-53). IEEE.

Chae, Y. M., Ho, S. H., Cho, K. W., Lee, D. H., & Ji, S. H. (2001). Data mining approach to policy analysis in a health insurance domain. *International Journal Of Medical Informatics*, 62(2-3), 103-111.

Chen, J. X., Zhao, H. H., & Wang, W. (2010). Investigative strategy for research on biological basis of traditional Chinese medicine syndrome: feature selection-based data mining methods. *Zhong xi yi jie he xue bao= Journal Of Chinese Integrative Medicine*, 8(8), 747-749.

Coulter, D. M., Bate, A., Meyboom, R. H., Lindquist, M., & Edwards, I. R. (2001). Antipsychotic drugs and heart muscle disorder in international pharmacovigilance: data mining study. *Bmj*, 322(7296), 1207-1209.

Çağlar, M. F., Çetişli, B., & Toprak, İ. B. (2010). Automatic recognition of parkinson's disease from sustained phonation tests using ann and adaptive neuro-fuzzy classifier. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1(2), 59-64.

Çalış, K., Gazdağı, O., & Yıldız, O. (2013). Reklam içerikli epostaların metin madenciliği yöntemleri ile otomatik tespiti. *Bilişim Teknolojileri Dergisi*, 6 (1), 1-7.

Çelik, S., Bozkurt, Ö. Ç., & Çeşmeli, M. Ş. (2018). İnsan omurgası veri setinin sinir-bulanık sınıflayıcı ile öznetelik tespiti ve sınıflandırılması. *Yönetim Bilişim Sistemleri Dergisi*, 4(1), 39-52.

Çetişli B. (2006). Öznetelik seçiminde dilsel kuvvetli sinir bulanık sınıflayıcı kullanımı. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 19(2), 109-130.

Çeşmeli, M. Ş., Bozkurt, Ö. Ç., Kalkan, A., & Pençe, İ. (2015). Yönetim bilişim sistemleri bölümü öğrencilerinin yönetim ve bilişim derslerindeki başarılarının veri madenciliği yöntemleri ile incelenmesi. *Yönetim Bilişim Sistemleri Dergisi*, 1(2), 36-47.

Danacı, M., Çelik, M. & Akkaya, A.E. (2010), Veri madenciliği yöntemleri kullanılarak meme kanseri hücrelerinin tahmin ve teşhisi. *Akıllı Sistemlerde Yenilikler ve Uygulama Sempozyumu*, 21-24 Haz. 2010, Kayseri, 9-12.

Da Rocha Neto, A. R., Sousa, R., Barreto, G. D. A., & Cardoso, J. S. (2011, June). Diagnostic of pathology on the vertebral column with embedded reject option. In *Iberian Conference on Pattern Recognition and Image Analysis* (pp. 588-595). Springer, Berlin, Heidelberg.

Da Rocha Neto, A. R., & de Alencar Barreto, G. (2009). On the application of ensembles of classifiers to the diagnosis of pathologies of the vertebral column: A comparative analysis. *IEEE Latin America Transactions*, 7(4), 487-496.

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZİNİTELİK SEÇİMİ

Delen, D., Walker, G., & Kadam, A. (2005). Predicting breast cancer survivability: a comparison of three data mining methods. *Artificial İntelligence İn Medicine*, 34(2), 113-127.

Dener, M., Dörterler, M., & Orman, A. (2009). Açık kaynak kodlu veri madenciliği programları: Weka'da örnek uygulama. *Akademik Bilişim*, 9, 11-13.

Demircioğlu, H. Z., & Bilge, H. Ş. (2015). Yumurtalık kanseri veri kümesindeki gen ifadelerinin veri madenciliği ile analizi. *Marmara Fen Bilimleri Dergisi*.

Doğan, Ş., & Türkoğlu, İ. (2008), Iron-Deficiency anemia detection from hematology parameters by using decision trees, *International Journal of Science & Technology*, Cilt 3, No 1, 85-92.

Dolgun, M. Ö., & Ersel, D. (2014). Doğrudan pazarlama stratejilerinin belirlenmesinde veri madenciliği yöntemlerinin kullanımı. *İstatistikçiler Dergisi: İstatistik ve Aktüerya*, 7(1), 1-13.

Erol, B., Çağlıyan, B., Tekeli, B., & Gürbüz, S. Z. (2015, May). Data-dependent micro-Doppler feature selection. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 1566-1569). IEEE.

Ewees, A. A., El Aziz, M. A., & Hassanien, A. E. (2019). Chaotic multi-verse optimizer-based feature selection. *Neural Computing and Applications*, 31(4), 991-1006.

Ferreira, D., Oliveira, A., & Freitas, A. (2012). Applying data mining techniques to improve diagnosis in neonatal jaundice. *BMC Medical Informatics And Decision Making*, 12(1), 143.

Fırat, M., Yurdusev, M. A., & Mermer, M. (2008). Uyarlamalı sinirsel bulanık mantık yaklaşımı ile aylık su tüketiminin tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 23(2).

Ganzert, S., Guttman, J., Kersting, K., Kuhlen, R., Putensen, C., Sydow, M., & Kramer, S. (2002). Analysis of respiratory pressure-volume curves in intensive care medicine using inductive machine learning. *Artificial İntelligence İn Medicine*, 26(1-2), 69-86.

Gharib, T. F., Nassar, H., Taha, M., & Abraham, A. (2010). An efficient algorithm for incremental mining of temporal association rules. *Data ve Knowledge Engineering*, 69(8), 800-815.

Göker, H., & Tekedere, H. (2017). FATİH projesine yönelik görüşlerin metin madenciliği yöntemleri ile otomatik değerlendirilmesi. *Bilişim Teknolojileri Dergisi*, 10(3), 291-299.

Göreke, V., Uzunhisarcıklı, E., & Güven, A. (2014). Gri seviyeli eşoluşum matrisleri kullanılarak sayısal mamogram görüntüsünden doku özneliklerinin çıkarılması ve yapay sinir ağı ile kitle tespiti. *Tıp Teknolojileri Ulusal Kongresi-TıpTekno'14*.

Gunal, S., Edizkan, R., Gerek, O. N., & Ece, D. G. (2008, April). Feature selection for power quality event classification. In *2008 IEEE 16th Signal Processing, Communication and Applications Conference* (pp. 1-4). IEEE.

Guo, S., Chen, J., Zhao, H., Wang, W., Yi, J., Liu, L., ... & Wang, Y. (2009). Building and evaluating an animal model for syndrome in traditional Chinese medicine in the context of unstable angina (Myocardial Ischemia) by supervised data mining approaches. *Journal Of Biological Systems*, 17(04), 531-546.

Gülşen, E., Gündüz, H., Cataltepe, Z., & Serinol, L. (2015, May). Big data feature selection and projection for gender prediction based on user web behaviour. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 1545-1548). IEEE.

Gündüz, A. E., Temizel, A., & Temizel, T. T. (2013, April). Feature detection and tracking for extraction of crowd dynamics. In *2013 21st Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.

Gümüşçü, A., Aydılek, İ. B., & Taşaltın, R. (2016). Mikro-dizilim veri sınıflandırmasında öznelik seçme algoritmalarının karşılaştırılması. *Harran Üniversitesi Mühendislik Dergisi*, 1(1), 1-7.

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

Hong, T. P., & Wu, C. W. (2011). Mining rules from an incomplete dataset with a high missing rate. *Expert Systems with Applications*, 38(4), 3931-3936.

Huang, D., & Chow, T. W. (2005). Efficiently searching the important input variables using bayesian discriminant. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 52(4), 785-793.

Irmak, S., Köksal, C. D., & Asilkan, Ö. (2012). Hastanelerin gelecekteki hasta yoğunluklarının veri madenciliği yöntemleri ile tahmin edilmesi. *Journal of Alanya Faculty of Business/Alanya İisletme Fakültesi Dergisi*, 4(1), 101-114.

İşler, Y., & Narin, A. (2012). Weka yazılımında k-ortalama algoritması kullanılarak konjestif kalp yetmezliği hastalarının teşhisi. *SDU Teknik Bilimler Dergisi*, 2(2).

Kayaalp, K. (2007), Asenkron Motorlarda veri madenciliği ile hata tespiti, Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü.

Kaya, C., Erkaymaz, O., Ayar, O., & Özer, M. (2017). C4. 5 Karar Ağacı Temelli Öznitelik Seçimi ile Video-Okülografi (VOG) Sinyallerinden Diyabetik Retinopati Hastalığının Sınıflandırılması Classification of Diabetic Retinopathy Disease. *Tıp Teknolojileri Ulusal Kongresi*, 75-78.

Kaya, M., & Bilge, H. Ş. (2016, May). A hybrid feature selection approach based on statistical and wrapper methods. In *2016 24th Signal Processing and Communication Application Conference (SIU)* (pp. 2101-2104). IEEE.

Kayım, G., Sarı, C., & Akgül, C. B. (2013, April). Facial feature selection for gender recognition based on random decision forests. In *2013 21st Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.

Keleş, A. E., & Kaya, M. (2014). Duvar inşa edilmesinde verimliliği etkileyen faktörlerin apriori veri madenciliği yöntemi kullanılarak analizi. *Akademik Bilişim Konferansı, AB2014 Bildiriler Kitapçığı*, 831-836.

Keleş, A. E., & Keleş, M. K. (2018). Genetik algoritma ile öznitelik seçimi kullanılarak yapım yönetiminde çalışan liderlik algısının tahmini. *Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 33(4), 97-110.

Khalilabad, N. D., Hassanpour, H., & Abbaszadegan, M. R. (2016). Fully automatic classification of breast cancer microarray images. *Journal of Electrical Systems and Information Technology*, 3(2), 348-359.

Kılınç, D., Borandağ, E., Yücalar, F., Tunalı, V., Şimşek, M., & Özçift, A. (2016). KNN algoritması ve r dili ile metin madenciliği kullanılarak bilimsel makale tasnifi. *Marmara Fen Bilimleri Dergisi*, 28 (3), 89-94.

Koçyiğit, Y., & Korürek, M. (2010). Emg işaretlerini dalgacık dönüşümü ve bulanık mantık sınıflayıcı kullanarak sınıflama. *İTÜDERGİSİ/d*, 4(3).

Kurt, Ç., & Erdem, O. A. (2012). Öğrenci başarısını etkileyen faktörlerin veri madenciliği yöntemleriyle incelenmesi. *Politeknik Dergisi*, 15(2), 111-116.

Lewis, B. P., Shih, I. H., Jones-Rhoades, M. W., Bartel, D. P., & Burge, C. B. (2003). Prediction of mammalian microRNA targets. *Cell*, 115(7), 787-798.

Liu, H., Dougherty, E. R., Dy, J. G., Torkkola, K., Tuv, E., Peng, H., ... & Zhao, Z. (2005). Evolving feature selection. *IEEE Intelligent systems*, 20(6), 64-76.

Mohebian, M. R., Marateb, H. R., Mansourian, M., Mañanas, M. A., & Mokarian, F. (2017). A hybrid computer-aided-diagnosis system for prediction of breast cancer recurrence (HPBCR) using optimized ensemble learning. *Computational And Structural Biotechnology Journal*, 15, 75-85.

Onan, A., & Korukoğlu, S. (2016). Metin sınıflandırmada öznitelik seçim yöntemlerinin değerlendirilmesi. *Akademik Bilişim*.

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZNETELİK SEÇİMİ

Oral, L. (2010). Uyarlamalı sinir-bulanık sınıflayıcı ile parmak izi tanıma ve dalgacık tabanlı momentlerle özellik çıkarma. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Isparta.

Özel, C., & Topsakal, A. (2014). Veri madenciliği kullanarak beton basınç dayanımının belirlenmesi. Cumhuriyet Üniversitesi Fen Edebiyat Fakültesi Fen Bilimleri Dergisi, 35 (1), 1-11.

Özseven, T. (2019). Konuşma tabanlı duygu tanımadada ön işleme ve öznetelik seçim yöntemlerinin etkisi. DÜMF Mühendislik Dergisi, 10(1), 99-112.

Pehlivanoğlu, M. K., & Duru, N. (2015). Veri madenciliği teknikleri kullanılarak ortaokul öğrencilerinin sosyal ağ kullanım analizi: Kocaeli ili örneği. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 3(2), 508-517.

Pençe, İ., Çetişli, B., Amasyalı, M. F., Çetin, M., Akbulut, C., Zihni, N. B., & Kurban, R. (2013). El yazı karakterlerinin kapalı cebirsel eğrilerle modellenmesi ve sınıflandırılması. Sigma, 5, 1-7.

Peixoto, R., Ribeiro, L., Portela, F., Santos, M. F., & Rua, F. (2017). Predicting Resurgery in Intensive Care-A data Mining Approach. Procedia Computer Science, 113, 577-584.

Pençe, İ. & Tarhan, L. (2016). Öğrenim sürelerini uzatan üniversite öğrencilerinin veri madenciliği yöntemleriyle tahmini. Uluslararası Yönetim Bilişim Sistemleri Konferansı, (3), 291-297.

Peng, H., Long, F., & Ding, C. (2005). Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy. IEEE Transactions on Pattern Analysis & Machine Intelligence, (8), 1226-1238.

Peng, M., Sundararajan, V., Williamson, T., Minty, E. P., Smith, T. C., Doktorchik, C. T., & Quan, H. (2018). Data on coding association rules from an inpatient administrative health data coded by International classification of disease-10th revision (ICD-10) codes. Data in Brief, 18, 710-712.

Reddy, S. K., Kodali, S. R. & Gundabathina, J. L. (2012). Classification of vertebral column using naïve bayes technique. International Journal of Computer Applications, 58 (7), 38-42.

Savaş, S., & Topaloğlu, N. (2013). Veri madenciliği yöntemi ile gsm şebekelerinin performans analizi. Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 26 (4), 741-751.

Savaş, S., Topaloğlu, N., & Yılmaz, M. (2012). Veri madenciliği ve Türkiye'deki uygulama örnekleri. İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi.

Sezgin, E., & Çelik, Y. (2013). Veri madenciliğinde kayıp veriler için kullanılan yöntemlerin karşılaştırılması. Akademik Bilişim Konferansı, Akdeniz Üniversitesi, 23-25.

Shi, Q., Zhao, H., Chen, J., Ma, X., Yang, Y., Zheng, C., & Wang, W. (2012). Study on TCM syndrome identification modes of coronary heart disease based on data mining. Evidence-Based Complementary and Alternative Medicine, 2012.

Sıramkaya, E. (2005), Veri madenciliğinde bulanık mantık uygulaması. Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü.

Singh, R. K., & Sivabalakrishnan, M. (2015). Feature selection of gene expression data for cancer classification: a review. Procedia Computer Science, 50, 52-57.

Strilka, R. J., Trexler, S. T., Sjulín, T. J., & Armen, S. B. (2017). A qualitative numerical study of glucose dynamics in patients with stress hyperglycemia and diabetes receiving intermittent and continuous enteral feeds. Informatics in Medicine Unlocked.

Şengür, D., & Tekin, A. (2014). Öğrencilerin mezuniyet notlarının veri madenciliği metotları ile tahmini. Bilişim Teknolojileri Dergisi, 6 (3), 7-16.

Tenev, A., Markovska-Simoska, S., Kocarev, L., Pop-Jordanov, J., Müller, A., & Candrian, G. (2014). Machine learning approach for classification of ADHD adults. International Journal of Psychophysiology, 93(1), 162-166.

RAHİM AĞZI KANSERİ (RİSK FAKTÖRLERİ) VERİ SETİ İÇİN ÖZİNİTELİK SEÇİMİ

Tarek, S., Elwahab, R. A., & Shoman, M. (2017). Gene expression based cancer classification. *Egyptian Informatics Journal*, 18(3), 151-159.

Terzi, Ö., Küçüksille, E., Ergin, G., & İlker, A. (2011). Veri madenciliği süreci kullanılarak güneş ışınımının tahmini. *Uluslararası Teknolojik Bilimler Dergisi*, 3 (2), 29-37.

Terzi, S. (2012). Hile ve usulsüzlüklerin tespitinde veri madenciliğinin kullanımı. *Muhasebe ve Finansman Dergisi*, (54), 51-64.

Uci Machine Learning Repository, <https://archive.ics.uci.edu/ml/datasets/Cervical+cancer+%28Risk+Factors%29>, (15.03.2019).

Vanitha, C. D. A., Devaraj, D., & Venkatesulu, M. (2015). Gene expression data classification using support vector machine and mutual information-based gene selection. *procedia computer science*, 47, 13-21.

Yağanoğlu, M., Bozkurt, F., & Günay, F. B. (2014). EEG tabanlı beyin-bilgisayar arayüzü sistemlerinde öznelik çıkarma yöntemleri. *Mühendislik Bilimleri ve Tasarım Dergisi*, 2(3), 313-318.

Yavaş, G. (2003). Using a data mining approach for the prediction of user movements in mobile environments. *Yüksek Lisans Tezi*, Bilkent University, Institute of Engineering and Science.

Yoldaş, M., Şakar, M. O., Dirlikli, M., & Kılınç, O. E. S. (2014). Mamografi imgelerinden HOG öznelikleri çıkartılarak hastaların kanser seviyelerinin belirlenmesi. *TMMOB EMO Ankara Şubesi Haber Bülteni İlk Bildiriler Konferansı*, 14-16.

Wall, D. P., Kosmicki, J., Deluca, T. F., Harstad, E., & Fusaro, V. A. (2012). Use of machine learning to shorten observation-based screening and diagnosis of autism. *Translational psychiatry*, 2(4), e100.

Wei, C. P., & Chiu, I. T. (2002). Turning telecommunications call details to churn prediction: a data mining approach. *Expert Systems With Applications*, 23(2), 103-112.

Wu, H., Yang, S., Huang, Z., He, J., & Wang, X. (2018). Type 2 diabetes mellitus prediction model based on data mining. *Informatics In Medicine*

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ

Mete Okan Erdoğan¹, Ümit Yılmaz^{2*}, Erol Özçekic³, Ediz Şaykol⁴

¹ Pamukkale Üniversitesi, Denizli Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü,
Bilgisayar Programcılığı Programı

meteokan@pau.edu.tr

² Balıkesir Üniversitesi, Bigadiç Meslek Yüksekokulu, Yönetim ve Organizasyon Bölümü, Lojistik Programı

umityilmaz@balikesir.edu.tr

³ Balıkesir Üniversitesi, Bigadiç Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, Elektrik Programı

erolozcekic@balikesir.edu.tr

⁴ Beykent Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği (İngilizce) Bölümü

ediz.saykol@beykent.edu.tr

* Sorumlu Yazar

1. GİRİŞ

Cilt kanseri, dünyada ve ülkemizde diğer kanserler gibi giderek artarak dikkati çekmektedir. En sık beyaz ırkta görülen melanom dışı cilt kanserleri ile malign melanoma kanseridir. Hayat boyunca oluşma oranının erkeklerde 33 kişide bir iken kadınlarda bu oran 52 kişide bir çıktığı bildirilmektedir (ACS, 2016: 14). Bunun en önemli sebebi de ultraviyole (UV) ışınlarıdır. Herkesin cilt kanseri olma riski bulunmaktadır, ancak, cildi açık tenli, cildinde çok sayıda ben ve lekeleri olan, uzun süreli güneşin altında kalan, çocukluk döneminde güneş yanığı hikayesi olan kişilerin cilt kanserine yakalanma riski daha çoktur (Sümen ve Öncel, 2018: 60). Tipik olarak, hasta geçmiş boyuncu, kırmızı, kabarık, topografik olarak anormal, büyüyen, kanama, kabuklanma veya değişen lezyonlar tanımlanır ve görsel olarak incelenir. Klinik uzmanlığa dayanarak, şüpheli lezyonların biyopsisine ve / veya tedavisine karar verilir. Şimdi klinik tanı doğruluğunu artırmak için birlikte kullanılan yeni teknolojiler mevcuttur. Buna karşılık, neoplazm ilk olarak 200 yıldan daha önce bir hastalık varlığı olarak kabul edildiğinden beri melanomun teşhisi ve tedavisi, önemli ölçüde gelişmiştir. Ancak melanomun erken teşhisinin önemi anlaşılmalıdır (Glazer, Rigel, Winkelmann, ve Farberg, 2017: 1-2).

Melanom özellikle ölümcül bir cilt kanseridir ve tüm cilt kanserlerinin sadece %4'ünü oluşturmasına rağmen, tüm cilt kanseri ölümlerinin %75'inden sorumludur. Melanom, eğer erken aşamalarında teşhis edilip tedavi edilirse tedavinin başarıyla sonuçlanması mümkündür, ancak tanı geç kalırsa melanom derinin derinliklerine doğru büyüyerek vücudun diğer bölgelerine yayılabilir. Cildin diğer bölümlerine yayılması, tedavisi zor olduğundan tehlikeli olabilir.

Herhangi bir vücut bölgesinde melanositlerin bulunması melanoma neden olmaktadır. Cildin ultraviyole radyasyona yoğun şekilde maruz kalması, melanomun ana nedenini oluşturmaktadır. Dermoskopi, cildin alt yüzey yapılarının görsel olarak incelenmesini mümkün kılmak için hafif ve yağa batırılmış olayların kullanımına dayanan invazif olmayan bir muayene tekniğidir. Her ne kadar dermoskopi kullanarak melanomun saptanması yardımsız gözlem tabanlı tespitlerden daha yüksek olsa da, tanısal doğruluğu dermatologların eğitimine bağlıdır. Melanomik nevinden melanom tanısı özellikle erken evrede kolay değildir. Bu nedenle doktorlar için otomatik tanı aracı çok önemlidir.

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ

Uzman dermatologlar tanı için dermoskopi kullanıyor olsalar bile, melanom tanısının doğruluğu yaklaşık %75-84 olarak tahmin edilmektedir.

Bilgisayar destekli tanılama, tanı doğruluğunu ve hızı arttırmada yardımcı olmaktadır. Bilgisayar insandan daha zeki değildir, ancak insan gözüyle kolayca algılanamayan renk değişimi, asimetri, doku özellikleri gibi bazı çıkarımlar yapabilmektedir. Melanom cilt kanseri teşhisini geliştirmek için yedi noktalı kontrol listesi, ABCD kuralı ve Menzies metodu gibi önerilen birçok sistem ve algoritma vardır. Bilgisayar görüşüne dayalı bir melanom tanısında anahtar adımlar şunlardır: cilt lezyonu görüntüsünün elde edilmesi, cilt lezyonunun cilt bölgesinden bölümlenmesi, lezyon bloğunun özelliklerinin çıkarılması ve özelliklerin sınıflandırılmasıdır. Birçok bilgisayarlı melanom tespit sisteminin özellik çıkarım metodolojisi, büyük ölçüde, uygulamanın etkinliği ve basitliği nedeniyle ABCD-dermoskopi kuralının geleneksel klinik algoritmasına dayanmaktadır. Etkinliği, kantitatif önlemlerin hesaplanabileceği asimetri, sınır düzensizliği, renk ve çap (veya diferansiyel yapılar) gibi bir melanom lezyonunun temel özelliklerini içermesinden kaynaklanmaktadır.

Melanom kanserinin erken evrede tespiti tedavi edilmesinde yardımcı olabilmektedir. Bilgisayarla görme tıbbi görüntü tanısında önemli bir rol oynamakta olup birçok mevcut sistem tarafından kanıtlanmıştır. Ele alınan çalışmada melanom cilt kanserinin görsel özellikleri dikkate alınarak yapay sinir ağları yönteminden faydalanılarak oluşturulan algoritmalar ile melanom cilt kanseri teşhisi yapılmaya çalışılmıştır. Sisteme giriş cilt lezyonu görüntüsüdür. Bu görüntüler daha sonra bahsi geçen görüntü işleme algoritma tekniklerine tabi tutularak, cilt kanseri varlığına dair sonuç çıkarmak için analiz edilir. Çıkarılan özellik parametreleri de incelemeye tabi tutulan görüntüyü et ben ve melanom kanseri lezyonu olarak sınıflandırmak için kullanılmıştır.

2. CİLT KANSERİ

Deri kanseri dünyadaki en yaygın kanser türüdür ve görülme sıklığı hızla artmaktadır. Deri kanserleri, büyük çoğunluğu epidermisteki hücrelerden türetilen melanom cilt kanseri ve melanom dışı cilt kanserine geniş ölçüde bölünmüştür. Melanom, melanositlerden kaynaklanırken, bazal hücreli karsinom ve skuamöz hücreli karsinom gibi melanom dışı deri kanserleri, keratinosit soy hücrelerinden kaynaklanmaktadır. Bu gruplar deri kanserlerinin %95'lik kısmını temsil etmektedir. Diğer deri tümörleri ise sadece çok küçük bir yüzdeye sahiptir. Ultraviyole ışınına maruz kalma cilt kanseri gelişiminde en önemli etyolojik faktördür (Lacy ve Alwan, 2013: 402). Cilt kanseri riski, ultraviyole ışınına maruz kalma ile genetik ve çevresel faktörlerin bir kombinasyonundan kaynaklanmaktadır (Craythorne ve Al-Niami, 2017: 431).




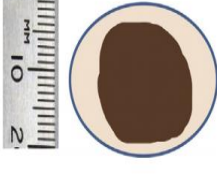

Deri anatomisinin iki ana katı vardır: epidermis (dış katman) ve dermis (iç katman). Epidermis, Squamous hücreleri adı verilen düz, ölçek benzeri hücreler ve bazal hücreler adı verilen yuvarlak hücrelerden oluşur. Epidermisin alt kısmı melanosit içerir. Melanositler, epidermisin alt kısmında bulunan ve cilde doğal rengini veren pigment olan melanin üreten pigment hücreleridir. Cilt güneşe maruz kaldığında, melanositler daha fazla pigment üreterek cildin bronzlaşmasına ya da koyulaşmasına neden olarak melanomlara neden olur (Alasadi ve ALsify, 2015: 67). Melanom, melanosit malign bir tümördür. Bu tür hücreler ağırlıklı olarak deride bulunur, ancak bağırsakta ve gözde de bulunabilmektedir. Melanom daha az yaygın cilt kanseri türlerinden biridir, ancak cilt kanseri ile ilgili ölümlerin çoğuna neden olmaktadır. Uzun yıllar süren yoğun laboratuvar ve klinik araştırmalara rağmen, bu tümörlerin erken cerrahi rezeksiyonu hala en büyük tedavi şansını vermektedir. Melanom en ciddi cilt kanseri türüdür. Melanosit adı verilen cilt hücrelerinde başlar (Das, Deshmukh, Badore, Ghulaxe, ve Patel, 2016: 112). Avrupa'da malign melanom insidansı, 100.000 kişi başına 4-14 hasta aralığında değişmektedir (Alendar, Drljević, Drljević, ve Alendar, 2009: 77).

1980'lerden önce, erken melanomun klinik özellikleri iyi tanımlanamamıştır. Melanom tespiti, tipik olarak uzun yıllara dayanan klinik deneyime dayanmaktadır. Hastalığın tedavi edilebilmesi için az deneyimli dermatologlar, diğer doktorlar ve genel halkı erken melanomun özellikleri konusunda eğitmek için kritik bir araca ihtiyaç vardı. 1985 yılında New York Üniversitesi'ndeki dermatologlar, erken melanomun klinik teşhisinde yardımcı olmak için ABCD (Asimetri, Sınır düzensizliği, Renk

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ

çeşitliliği, Çap> 6 mm) kısaltmasını tasarlamışlardır. Cilt lezyonu segmentasyonunu gerçekleştirme özellikleri Tablo 1’de özetlenmiştir (Glazer ve diğ., 2017: 1-2).

Tablo 1: Erken Melanomun Tespiti için ABCDE Araçları

Özellik	Açıklama	Görünüm
Asimetri	Lezyonlar kolayca ikiye bölünemez, böylece bir yarısı diğerine benzeyebilir.	
Sınır düzensizliği	Sınırlar tipik olarak iyi tanımlanmamıştır ve düzensiz biçimdedir.	
Renk çeşitliliği	Bir veya daha fazla renk veya renkli değişimler. Renkler sıklıkla siyah, kahverengi ve tan içerir. Daha az sıklıkla kırmızı, beyaz veya mavi olabilir.	
Çap	Çoğu erken melanom > 6 mm'dir (yaklaşık olarak bir kalem silgisinin boyutu).	
Gelişen	Boyut, şekil, renk, topografya, sansasyon, tutarlılık veya çevresindeki ciltte değişen lezyonlar.	

Sürveyans Epidemiyolojisi ve son sonuçları verilerine göre, melanom tüm kanser ölümlerinin %4'ünden ve cilt kanseri ile ilgili her 7 ölümden 6'sından sorumlu olan altıncı ölümcül hastalıktır (Riker, Zea, ve Trinh, 2010: 56). Birçok hasta için küratif cerrahi mümkündür. Bu nedenle melanomun erken teşhisi ve araştırılması önemlidir. Amerikan Kanser Ortak Komitesi (The American Joint Committee on Cancer), bir kişinin kanserini tanımlayan ve tümör derinliğine, ülserasyonun varlığına, lenf nodu tutumuna ve metastazların tanımlanmasına dayanan, doğrulanmış bir evreleme sistemi geliştirmiştir. Bu sisteme göre melanom evreleri aşağıdaki gibi açıklanabilir (Walters-Davies, 2013: 257-260):

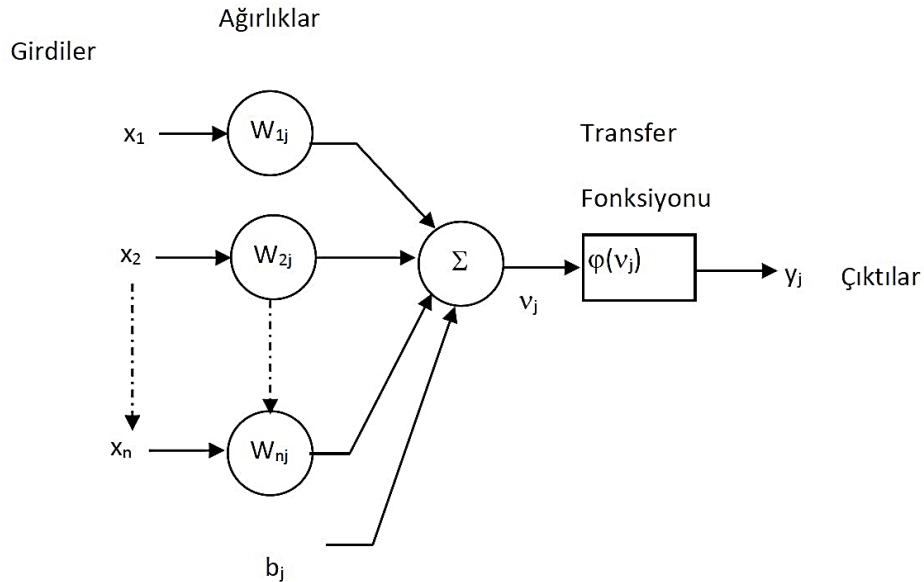
- Evre 0: Melanom cildin üst yüzeyinde bulunur ve daha derin katmanlara yayılmaz.
- Evre 1 (metastaz):
 - Evre 1a: Melanom 1mm kalınlığında, ülserli değil ve $1/\text{mm}^2$ 'den az bir mitotik orana sahiptir.

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ

- Evre 1b: Melanom 1mm'den az kalınlıkta ve ülserlidir veya 1,01 – 2mm kalınlığındadır ve ülserli değildir, ve en az 1/mm² mitotik orana sahiptir.
- Evre 2:
 - Evre 2a: Melanom 1,01–2mm kalınlığında ve ülserli veya 2,01–4mm kalınlığında ve ülserli değildir.
 - Evre 2b: Melanom, 2,01–4mm kalınlığında ve ülserli veya 4 mm'den kalın ve ülserli değildir.
 - Evre 2c: Melanom 4mm'den kalın ve ülserlidir.
- Evre 3: Evre 3 melanomları, lenf bezlerine veya melanomlara en yakın olan lenfatik damarlara ya da diğer vücut kısımlarına yayılmaz. Evre 3'teki melanomun derinliği önemli değildir çünkü evreleme, lenf nodlarının sayısına, melanom hücrelerinin boyutuna ve melanom hücrelerinin lenfatik damarlara sızmasına bağlıdır.
- Evre 4: Melanomlar cildin uzak kısımlarına, uzak lenf bezlerine veya diğer organlara, genellikle de akciğere, karaciğere veya beyine metastaz yapar. Bu ileri veya metastatik melanom olarak adlandırılır.

3. YAPAY SİNİR AĞLARI

Yapay sinir ağı insan beyninin çalışma prensiplerinden esinlenerek oluşturulan bir yapıdır. Bu nedenle, bilgiler arasında ilişki kurabilme yeteneğini sahiptir. İnsan beyni gibi öğrenebilir, öğrendiklerini hatırlar, ezberler ve genellemeler yapabilir. Nöronlar beyindeki işlemleri gerçekleştirirler. Bu nöronlar kendilerine gelen sinyalleri bazı işlemlerden geçirerek daha sonraki nöronlara iletirler bu sayede bazı tepkiler meydana gelir. Tıpkı beyinde bulunan nöronlara benzer yapay nöronlar bulunmaktadır. Bu yapay nöronların birbirlerine çeşitli mimarilerle bağlanması ile yapay sinir ağı oluşmaktadır. Bir yapay nöronda girdiler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkış fonksiyonu bulunmaktadır. Şekil 1'de yapay sinir ağlarında kullanılan bir yapay nöron yapısı görülmektedir (Şen, 2004: 180-185).



Şekil 1: Yapay Sinir Ağlarında Kullanılan Bir Nöronun Yapısı

Şekil 1'deki X değerleri girdiler olup diğer hücrelerden veya dışarıdan hücreye dahil olan bilgilerdir. Bilgiler bağlantılar üzerindeki ağırlıklar ile hücreye girer ve ilgili girişin hücre üzerindeki etkisini belirler. Bir ağırlığın diğerine göre büyük olması o girişin sinire daha güçlü bağlanması anlamına gelmektedir. Bu bilgiler daha sonra toplama fonksiyonundan geçirilerek bir hücreye gelen

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ

net girdiler hesaplanır. Hesaplama şu şekilde yapılır; Toplama fonksiyonunun değeri her bir ağırlığın ait olduğu girişlerle çarpımının toplamına eşik değerinin toplanması ile elde edilir. Elde edilen bu değer transfer veya aktivasyon fonksiyonundan geçirilerek hücre çıktısı oluşturulur. Aktivasyon fonksiyonunun sürekli ve toplanabilir olması ağı eğitiminde kullanılan algoritmalar sayesinde arzu edilmektedir. İyi sonuç elde edebilmek için literatürde birçok farklı aktivasyon fonksiyonları kullanılmaya rağmen genellikle tanjant-hiperbolik, sigmoid ve doğrusal fonksiyonları tercih edilmektedir. Sigmoid ve doğrusal fonksiyonların iyi sonuçlar verdiği gözlenmektedir. Temel işlemciler olan nöronların toplanması ile yapay sinir ağının mimarileri oluşturulmaktadır. Ağ mimarisinde X girdilerin ağa sokulduğunda bir giriş tabakası, giriş tabakasından gelen bilgilerin işlenip çıkış katmanına iletiildiği bir gizli tabaka ve son olarak da çıktılarının elde edildiği bir çıkış tabakası bulunmaktadır (Kıyıldı, 2017: 1644).

Birçok araştırmacı cilt kanseri tespiti için bilgisayarla görme yaklaşımı üzerinde çalışmaktadır. Cilt lezyonunun segmentasyonu için mevcut sistemler ya manuel, ya yarı otomatik ya da tam otomatik kenar algılama yöntemleri kullanmaktadır (Jain, Jagtap, ve Pise, 2015: 736).

Anlatılmada, göstermede büyük güçlük çekilen ve çözümü insanlar tarafından güçlükle yapılan problemlerin neticeye vardırılmasında yapay zekâ yöntemleri kullanılmaktadır. Yapay sinir ağları, yapay zeka ve makine öğrenmesi çalışmalarında sıklıkla kullanılan, çalışma şekli olarak insan beyninin işleyiş şekli örnek alınarak geliştirilmiş bir yaklaşımdır. Yapay sinir ağları insan beyninin en önemli özelliklerinden öğrenmeyi yerine getiren bilgisayar sistemleridir. Yapay sinir ağları belli sayıda yapay sinir hücresinin bir araya gelip belli bir mimari oluşturmasıyla ortaya çıkar (Şengür ve Tekin, 2013: 9). Bu mimari çok katmanlı bir yapıda olup ilk katman giriş katmanıdır. Son katman ise çıkış katmanıdır. Arada kalanlar ise ara katman olarak adlandırılır. Sayıları birden fazla olabilir. Ortak adları gizli katmandır (Özçekiç, Öztürk, ve Şaykol, 2019).

Yapay sinir ağları uygulamasının başarısı, uygulanacak olan yaklaşımlar ve deneyimlerle yakından ilgilidir. Uygulamanın başarısında uygun yöntemi belirlemek büyük önem taşır. Yapay sinir ağının geliştirilmesi sürecinde ağı yapısına ve işleyişine ilişkin aşağıda belirtilen kararların doğru bir şekilde verilmesi gerekir (Yılmaz, 2010: 63-64):

- Yapay Sinir Ağları Ağ Yapısının Seçimi,
- Öğrenme Algoritmasının Seçimi,
- Ara Katman Sayısının Belirlenmesi,
- Nöron Sayısının Belirlenmesi,
- Normalizasyon,
- Performans Fonksiyonunun Seçimi.

Yapay sinir ağları, birçok istatistiksel algoritmanın tahmin yaptığı şekilde aynı şekilde öğrenir ancak genellikle istatistiksel algoritmalarından çok daha yavaş olur (Sarle, 1994: 1). Yapay sinir ağları mimarisi, sınırlar arası bağlantı durumuna göre veya ağı akış yönüne göre ileri ve geri beslemeli ağlardır. İleri beslemeli ağlarda işlenecek öğeler genelde katmanlı yapıya ayrılmışlardır. Mevcut olan işaretler, girdi katmanından çıktı katmanına tek yönlü bağlantılar yardımıyla aktarılır. İleri beslemeli sistemde, hücre yapıları katmanlı yapı halinde düzenlenip, bir katmandaki hücre çıkışları bir sonrakine ağırlık değerlerine göre giriş değeri olarak gözüktür. İlk katmanın, dışarıdan giren bilgilerde değişiklik yapmaz ve bu bilgileri hücrelere iletir. Bu hücrelerde gizli olan katmanda bulunmaktadır. Böylece bilgiler, ağda bulunan gizli katmanda ve daha sonra çıkış katmanında işlemlerden geçtikten sonra, ağdan çıkış bilgisi belirlenmiş olur (Rojas, 1996: 30).

Geri beslemeli ağ mimari modeli, genelde danışmansız öğrenme kurallarının kullanıldığı ağlarda tercih edilmektedir. Bu modelde en az bir hücre çıkışı kendisine veya başka ağ hücrelerine giriş olarak verilir. Genelde geciktirme bilgisi sayesinde geri besleme işlemleri yapılır. Geri besleme, katmalardan bulunan arasında bulunan hücreler arasında olabilir. Ayrıca bir katmanda bulunan hücreler arasında da olabilmektedir. Geri beslemeli yapay sinir ağları bu özelliği ile dinamik bir davranış göstermektedir. Bu davranış biçimi doğrusal değildir (Öztürk ve Şahin, 2018: 32). Yapay

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ

sinir ağlarının öğrenmesi için iki yaklaşım bulunmaktadır. Bunlar; danışmanlı ve danışmansız öğrenmedir.

Günümüzde yapay sinir ağları ile ilgili dünya çapında araştırmalar ve geliştirme çalışmaları yapılmaktadır. Yapay sinir ağlarını eğitmek uzun zaman ve güçlü donanım gerektirdiğinden, araştırmalar özellikle bu sorunu çözmeye odaklanmıştır. Amaç daha verimli, etkin ve yeni öğrenme algoritmaları keşfetmektir. 1943 yılından günümüze kadar olan süreçte yaşanan gelişmelerde bu konu temel odak noktasıdır (Keskenler ve Keskenler, 2017: 16).

Yapay sinir ağlarının kullanım konularına baktığımızda sesi tanıma işlemi, yazılan değişik karakterler tanıma, robotik işlemler ve kontrolleri, yapılan resim işleme ve girişi yapılan yüz tanıma araçlarında çok sık olarak kullanıldığı görülmektedir. İnsanın önemli özellikleri beyin ve algılama sistemlerinin modellenmesi, son zamanlarda yüz tanıma sistemlerinde artış olmuştur. Sanayi alanında da kullanılmaktadır. Özellikle arıza analizi ve arıza tespiti, tıp alanında kullanılan sinyallerinin analizi, kanserli yapıların analizi, transplantasyon zamanlarının optimizasyonu, ayrıca silahların otomasyonu, hedeflerin takip edilmesi, objeleri algılama, ayırma, tanıma konularında faydalanılır. Fabrikalarda üretim sistemlerinin maksimum ve firesiz çalışması için, ürün ve kalite analizi gibi alanlarda kullanılmaktadır (Çakır, Ertunç, ve Ocak, 2009: 74).

Yapay sinir ağlarının kullanımını kolaylaştırmak için yazılımcılar için çeşitli programlama dillerinde birçok kütüphane dahil edilerek, kullanım için araç geliştirilmiştir. Bunlardan genel olarak kabul edilen ve çok sık kullanılanlardan birkaçı aşağıdaki gibidir (Arı ve Berberler, 2017: 56).

- Stuttgart Neural Network Simulator (SNNS) Stuttgart Üniversitesi'nde bulunan IPVR enstitüsü tarafından geliştirilmiş olan yapay sinir ağları için bir simütördür. Bu simütör ortamı sinir ağı araştırmaları için kullanılmaktadır. Bu simütör ortamı etkin ve esnek bir simülasyon ortamıdır.
- FANN (Fast Artificial Neural Network Library), algılayıcıları çok katmanlı olan algılayıcıları araştırmaya göre kullanmayı sağlayan, C programlama dilinde hazırlanmış bir yapay sinir ağı kütüphanesidir.
- JOONE (Java Object Oriented Neural Engine), Java ortamı kullanılarak geliştirilmiş bir yapay sinir ağı kütüphanesidir.
- Matlab Neural Network Toolbox, MATLAB için geliştirilen bu araç sayesinde, yapay sinir ağlarının tasarlayabilmekteyiz. Ayrıca ağların simülasyonunu sağlayabilmekteyiz. Böylece ağlar gerçekleştirilebilmekte ve görselleştirilmektedir.


Ele alınan araştırmada melanom cilt kanserinin görsel özellikleri dikkate alınarak oluşturulan algoritmalar ile melanom cilt kanseri tespiti yapılmaya çalışılmıştır.

4. YÖNTEM

Bu çalışmada yapay sinir ağları MATLAB'da oluşturulmuştur. Görüntü işleme araçlarını kullanarak melanom cilt kanseri tespiti için bilgisayar destekli bir yöntem sunulmaktadır. Sisteme girdi değeri olarak cilt lezyonu görüntüsü işlenmiş ve sonrasında görüntü işleme teknikleri uygulanarak, cilt kanseri varlığına dair sonuç çıkarmak için analiz yapılmıştır. Yapay sinir ağları üzerinde yapılan çalışmalar beyinde bulunan nöronların modellenmesi olarak karşımıza çıkmaktadır. Daha sonra bu modeller bilgisayarlar kullanılarak uygulanması yapılmaya başlamıştır. Nöronlar birbirine bağlantılarla bağlanırlar. Bağlantıların girdisinin şiddetini veya diğer bir deyişle önemini ortaya çıkaran sayısal bir ağırlığa sahiptir. Ağırlıklar, öğrenmeyi gerçekleştirmek için kullanılırlar. Yapay sinir ağlarındaki uzun süreli belleğin temel aracı olan ağırlıkların tekrar tekrar ayarlanması ile gerçekleştirir (Arı ve Berberler, 2017: 56).

Yapay sinir ağı olarak ileri beslemeli çok katmanlı yapı kullanılmıştır. Çok katmanlı ileri beslemeli yapay sinir ağında ise gizli katmanların birden fazla mevcuttur ve Şekil 2' de gösterildiği gibidir. Bu sebeple giriş katmanından gelen verilere birtakım işlemler uygulanabilmektedir.

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ



Şekil 2: İleri Doğru Beslemeli Çok Katmanlı Yapay Sinir Ağı

İleri doğru beslemeli çok katmanlı yapay sinir ağlarında gecikme yoktur. Bunun sebebi işlemin girişlerden çıkışlara doğru ilerlemesidir. Elde edilen çıktı değerleri, öğreticiden alınmak istenen çıktı değeriyle karşılaştırılarak bir hata sinyali elde edilmekte ve bu sayede ağ ağırlıkları güncellenmektedir. Ele alınan çalışmada melanom cilt kanserinin tahmini için ileri beslemeli yapay sinir ağ modeli kullanılmıştır. Ağın eğitiminde Levenberg-Marquardt algoritması kullanılmıştır. Levenberg-Marquardt algoritmasını tercih edilmesinin sebebi yapay sinir ağlarının eğitiminde sağlamış olduğu hız ve kararlılıktır.

Bir veri analizi yapmadan önce yapılacak iş önce verileri hazırlamaktır. Bu uygulamadaki veri sayısı toplam 2500 olup 500 iterasyon, 10 gizli katman ve gizli katman başına 2'şer nöron kullanılmıştır. Ayrıca eğitim için %70, test için %30 oranı belirlenmiştir.

4.1. Bulgular

Melanom cilt kanseri fotoğrafları ile cilt beni fotoğrafları kullanılarak ağ eğitilmiştir. Bunun için ağ girdi değerleri tanımlanmıştır. Girdi değerleri melanom cilt kanseri ve cilt beni görüntüleridir. Bahsi geçen görüntüler için örnekler Şekil 3'te gösterilmiştir.



Şekil 3: Cilt Beni ile Melanom Cilt Kanseri Görünümü

Ağın girdi ve çıktı elemanları nümerik olmak zorundadır. Bundan dolayı girdileri oluşturan görüntülere Şekil 4'te gösterilen işlemler uygulanmıştır. Bu işlemlerden sonra görüntü matrisleri 2500x1'lik sütun matrisine dönüştürülerek girdi matrisi oluşturulmuştur. Girdi matrisinin birinci sütunu melanom görüntüsünün sütun değerini, ikinci sütunu ise cilt beninin sütun değerini tutmaktadır.

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ


```
1 % girişleri ayarlıyoruz.
2 - rr1 = imread('rr1.jpg');
3 - rr2 = imread('rr2.jpg');
4 - rr1=im2bw(rr1);
5 - rr1=imresize(rr1,[50 50]);
6 - rr1=double(rr1);
7 - rr1=reshape(rr1,2500,1);
8 - rr2=im2bw(rr2);
9 - rr2=imresize(rr2,[50 50]);
10 - rr2=double(rr2);
11 - rr2=reshape(rr2,2500,1);
12 % Bu matrisleri ağı girdi olarak sunmak için giriş matrisinde topluyoruz.
13 - Giris=zeros(2500,2);
14 - Giris(:,1)=rr1;
15 - Giris(:,2)=rr2;
16 % Temsili çıkış matrisimiz.
17 - Target=eye(2);
18 - Target
```

Şekil 4: Giriş Düzenleme

Melanom ve cilt benini temsil edecek ve “Çıktı matrisi= $\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ ” şeklinde gösterilen bir çıktı matrisine gereksinim duyulmaktadır. Şekil 5’te gösterilen işlemler uygulanarak Şekil 6’daki ağ oluşturulmuş ve sonrasında ağı eğitme işlemi gerçekleştirilmiştir. Eğitim sonrası elde edilen çıktı Şekil 7’de gösterilmiştir.

```
19 % % iki katmanlı bir ağ oluşturuyoruz.
20 - net=newff(minmax(Giris),[10,2],{'logsig' 'logsig'},'trainscg');
21 % % Ağı eğitmeye başlıyorum.
22 % % Döngü sayısı:
23 - net.trainParam.epochs=500;
24 % % Ağı eğitiminin sonlanma noktası:
25 - net.trainParam.goal=1e-5;
26 % % Ağı girdi ve çıkış matrisine göre eğitilmesi:
27 - net=train(net,Giris,Target);
```

Şekil 5: Ağı Oluşturma ve Eğitme



Şekil 6: Geliştirilen Sinir Ağı

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ



Şekil 7: Ağın Eğitim Performansı

Yapay sinir ağları, öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşmadığı durumlar hakkında genelleme yapabilmektedir. Yapay sinir ağının hata oranı %22 olarak saptanmıştır. Oluşturulan yapay sinir ağı %22'lik bir hata oranı ile melanomlu görüntüyü tahmin edebildiği için çalışmada başarılı bir sonuç elde edildiği sonucuna varılabilir. Öğrenme aşamasında veriler kullanılarak girdi ile çıktı arasındaki hata minimum yapılmakta ve girdi-çıkıtı değişkenleri arasında en az hatayı veren yapay sinir ağı modeli kurulabilmektedir.

5. SONUÇLAR

Melanom ciddi ve bazen hayatı tehdit eden bir kanserdir. Melanosit içeren vücudun herhangi bir yerinde oluşabilmektedir. Melanomun ana nedeni cilde ulaşan ultraviyole radyasyona aşırı maruz kalmaktır. Güneşten ve diğer kaynaklardan gelen ultraviyole ışınları cilt hücrelerine zarar vererek hücrelerin anormal şekilde büyümesine neden olabilir. Kanserinin erken teşhisi, hastanın uygun bir tedavi görmesine yardımcı olabilmektedir (Banjan, Dalvi, ve Athavale, 2017: 24).

Geçtiğimiz yıllarda, yüksek doğruluk ve performansa sahip invaziv olmayan bir araç olarak tıbbi görüntüleme dikkat çekmiştir. Bu nedenle, görüntü işleme mekanizmaları, invazif aktiviteler olmadan hastalığı teşhis ve tedavi etmek için kullanılabilir. Bu çalışmanın amacı, et beni ile melanomları doğru teşhis ve tespit etmektir. En önemli adım, görüntüyü yüksek doğrulukla segmentlere ayırmaktır (Nezhadian ve Rashidi, 2017: 5).

Bilgisayar tabanlı teknikleri kullanan erken melanom cilt kanseri tanı sistemi konvansiyonel Biyopsi yöntemlerinden daha etkilidir. Tespit için harcanan zamanın yanı sıra maliyet, bu önerilen metodolojide daha azdır. Metodoloji, cilt kanseri tespiti için yapay zekâ ve dijital görüntü işleme içermektedir. Ele alınan çalışmada, melanom cilt kanserinin tespiti için bilgisayar destekli bir tanı sistemi tasarımı hazırlamak üzerinedir. Yapay sinir ağı tabanlı sınıflandırıcı, kalıp tanıma uygulamalarının yanı sıra karar vermede de çok etkili olduğunu kanıtlamıştır. Ayrıca, önerilen sistemin melanom cilt kanserini daha doğru teşhis etmek için hastalar ve doktorlar tarafından etkili bir şekilde kullanılabilmesi sonucuna varılabilir. Bu araç, tıp alanındaki uzmanların bulunmadığı alanlar için de kullanışlı olabilir. Ayrıca geliştirilen sistem, melanom cilt kanserinin otomatik tanılama amacına hizmet edebilir.

Hatanın yüksek olmasının nedeni ağ eğitimi sırasında eğitim setinin az olmasıdır. Sonuçta ağ eğitmek için kullanılan görüntüler az olmasına karşın yüksek tutarlılıkla fotoğrafları değerlendirmiştir.

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ

MATLAB kullanılarak oluşturulan algoritma probleme cevap vermiştir. Bu çalışma görüntüler arttırılarak daha geniş ve daha derin sınıflandırmalar yapılabileceğini göstermiştir. Ayrıca teşhis performansını ve hızını arttırmak için geniş ve eksiksiz bir görüntü veritabanı üzerine birçok çalışmaya ihtiyaç vardır.

6. KAYNAKÇA

- ACS. (2016). *Cancer facts & figures*. Atlanta: American Cancer Society.
- Alasadi, A. H., ve ALSafy, B. M. (2015). Early detection and classification of melanoma skin cancer. *International Journal of Information Technology and Computer Science*, 7(12), 67-74. doi:10.5815/ijitcs.2015.12.08
- Alendar, F., Drljević, I., Drljević, K., ve Alendar, T. (2009). Early detection of melanoma skin cancer. *Bosnian journal of basic medical sciences*, 9(1), 77-80. doi:10.17305/bjbms.2009.2861
- Arı, A., ve Berberler, M. E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta INFOLOGICA*, 1(2), 55-73.
- Banjan, N., Dalvi, P., ve Athavale, N. (2017). Melanoma Skin Cancer Detection by Segmentation and Feature Extraction using combination of OTSU and STOLZ Algorithm. *SSRG International Journal of Electronics and Communication Engineering*, 4(4), 21-25.
- Craythorne, E., ve Al-Niami, F. (2017). Skin cancer. *Medicine*, 45(7), 431-434. doi:10.1016/j.mpmed.2017.04.003
- Çakır, Ş., Ertunç, H. M., ve Ocak, H. (2009). Yapay sinir ağları kullanılarak karbonat kayalarındaki dokunun tanınmasına bir örnek: Akveren formasyonu. *Uygulamalı Yerbilimleri Dergisi*, 8(2), 71-79.
- Das, P., Deshmukh, N., Badore, N., Ghulaxe, C., ve Patel, P. (2016). A review article on melanoma. *Journal of Pharmaceutical Sciences and Research*, 8(2), 112-117.
- Glazer, A. M., Rigel, D. S., Winkelmann, R. R., ve Farberg, A. S. (2017). Clinical diagnosis of skin cancer: enhancing inspection and early recognition. *Dermatologic Clinics*, 35(4), 409-416. doi:10.1016/j.det.2017.06.001
- Jain, S., Jagtap, V., ve Pise, N. (2015). Computer aided melanoma skin cancer detection using image processing. *Procedia Computer Science*, 48, 735-740. doi:10.1016/j.procs.2015.04.209
- Keskenler, M. F., ve Keskenler, E. F. (2017). Geçmişten günümüze yapay sinir ağları ve tarihçesi. *Takvim-i Vekayi*, 5(2), 8-18.
- Kıyıldı, R. K. (2017). *Türkiye için yapay sinir ağları yöntemi ile trafik kazası tahmini araştırması*. Paper presented at the 5th International Symposium on Innovative Technologies in Engineering and Science, Baku - Azerbaijan.
- Lacy, K., ve Alwan, W. (2013). Skin cancer. *Medicine*, 41(7), 402-405. doi:10.1016/j.mpmed.2013.04.008
- Nezhadian, F. K., ve Rashidi, S. (2017). *Melanoma skin cancer detection using color and new texture features*. Paper presented at the 2017 Artificial Intelligence and Signal Processing Conference (AISP).
- Özçekiç, E., Öztürk, Ü., ve Şaykol, E. (2019). *Öğrencinin akademik başarısının yapay sinir ağları ile tahmin edilmesi*. Paper presented at the 21. Akademik Bilişim Konferansı, Ordu.
- Öztürk, K., ve Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Riker, A. I., Zea, N., ve Trinh, T. (2010). The epidemiology, prevention, and detection of melanoma. *Ochsner Journal*, 10(2), 56-65.

YAPAY SİNİR AĞLARI İLE MELANOM CİLT KANSERİNİN TESPİTİ

Rojas, R. (1996). *Neural networks: a systematic introduction*. Berlin: Springer Science & Business Media.

Sarle, W. S. (1994). *Neural networks and statistical models*. Paper presented at the Nineteenth Annual SAS Users Group International Conference, Dallas, Texas.

Sümen, A., ve Öncel, S. (2018). Türkiye'de cilt kanseri ve güneşten korunmaya yönelik yapılan araştırmaların incelenmesi. *Türkiye Klinikleri Hemşirelik Bilimleri Dergisi*, 10(1), 59-69. doi:10.5336/nurses.2017-56858

Şen, Z. (2004). *Yapay sinir ağları ilkeleri*. İstanbul: Su Vakfı.

Şengür, D., ve Tekin, A. (2013). Öğrencilerin mezuniyet notlarının veri madenciliği metotları ile tahmini. *Bilişim Teknolojileri Dergisi*, 6(3), 7-16.

Walters-Davies, R. (2013). Skin cancer: Types, diagnosis and prevention. *Clinical Pharmacist*, 5, 257-260. doi:10.1211/CP.2013.11129534

Yılmaz, Ü. (2010). *Altı sigma ve yapay sinir ağlarının tekstil sektöründe karşılaştırmalı bir uygulaması*. (Yüksek Lisans Tezi), Uludağ Üniversitesi, Bursa.

BULANIK MANTIK TEMELLİ BİREYSEL KREDİ BAŞVURUSU DEĞERLENDİRME SİSTEMİ TASARIMI

Turgut Duman¹, Ümit Yılmaz^{2*}, Erol Özçekiç³ Atınç Yılmaz⁴

¹ *Beykent Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı*

turgutduman@gmail.com

² *Balıkesir Üniversitesi, Bigadiç Meslek Yüksekokulu, Yönetim ve Organizasyon Bölümü, Lojistik Programı*

umityilmaz@balikesir.edu.tr

³ *Balıkesir Üniversitesi, Bigadiç Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, Elektrik Programı*

erolozcekic@balikesir.edu.tr

⁴ *Beykent Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği (Türkçe) Bölümü*

atincyilmaz@beykent.edu.tr

** Sorumlu Yazar*

1. GİRİŞ

Bankaların, faaliyet gösterdikleri çevrelerde yaşayan bireylerin sosyo-ekonomik yaşamları üzerindeki rolü özellikle son yıllarda daha da fazla önem kazanmaktadır. Genel olarak, bankalar kredi arzını etkileyerek reel ekonomik faaliyet üzerinde büyük bir etkiye sahiptir. Özellikle günümüzde bankalar, karşı karşıya kalınan riske rağmen kredi verme hususunda hizmet alanlarını genişletme eğilimindedir. Bankacılık sisteminde özellikle kredi verme alanında ortaya atılan övgüye değer fikirlere rağmen, almış oldukları krediyi ödeyemeyen tüketicilerin varlığı, bankalara kredi verme aşamasında birtakım değerlendirme yöntemlerini izleme gereksinimi doğurmuştur (Antwi, Atta Mills, Atta Mills, ve Zhao, 2012: 376-377).

Batı toplumlarında bireysel kredilerin kullanımı artmaya devam ettikçe, kredi kullanımı ve kredi kullanıcıları ile ilgili araştırmalar buna göre artmıştır (Kamleitner ve Kirchler, 2006: 281).

Kredi riski, bankacılık problemlerinin ana kaynağıdır (Wang, Chen, ve Chiang, 2017: 115). Bireysel kredilerin bankacılık sektöründeki artan oranına bakıldığında, kişisel kredilerin temerrüt riskini dikkate almak gerekir. Etkin bir bireysel kredi risk yönetim sistemi borçlu temerrüt oranını ve kredi kaybını azaltmakla beraber aynı zamanda kredi analiz maliyetini de düşürebilmektedir. Bu nedenle, bankacılık sektörünün ve finansal kurumların kredi faaliyetlerini etkin bir şekilde yürütebilmelerini sağlamak ve vadesi geçmiş kredilerini azaltmak amacıyla müşterilerin temerrütlerini engellemeleri için bir dizi etkili bireysel kredi temerrüdü öngörme modeli oluşturma zorunluluğu vardır (Tsai, Lin, Cheng, ve Lin, 2009: 11682). Geleneksel olarak, kredi notlamasının temel amacı, müşterilerin temerrüde düşme eğilimi gösterdiğinde iyi müşterileri kötü müşterilerden ayırt etmektir (Baesens, Van Gestel, Stepanova, Van den Poel, ve Vanthienen, 2005: 1089).

Bireysel kredi temerrüt faktörü, eğitim düzeyi, yaş, hizmet süresi, ikametgâh, aile geliri, aile yapısı, kredi geliri oranı, kredi kartı borçları, diğer borçlar, cinsiyet, sabit varlıkların değeri, borç vadesi gibi tüm bireysel kredilerin özellikleri ve ipoteğinin olup olmaması ile ilgilidir (Zhang, 2011: 2). Ele alınan çalışmada krediye başvuran kişinin veya eşinin hacizli mal, protestolu senet ve karşılıksız çek durumu ile, krediye başvuran kişinin kredi kayıt bürosu (KKB) puanı, yaşı ve bankalara olan mevcut borç durumu gibi bireysel kredi temerrüt faktörleri dikkate alınmıştır. Krediye başvuran

BULANIK MANTIK TEMELLİ BİREYSEL KREDİ BAŞVURUSU DEĞERLENDİRME SİSTEMİ TASARIMI


kişinin veya eşinin hacizli malı, protestolu senedi veya karşılıksız çeki varsa kredi başvurusu olumsuz sonuçlanmaktadır. Kredi kayıt bürosu puanının yüksek olması kredi temerrüt olasılığını düşürmektedir. Yaş ne kadar büyük olursa kredi temerrüt olasılığı daha da düşmektedir. Bankalara olan borç ne kadar yüksekse, temerrüt olasılığı da o kadar fazladır.

2. BİREYSEL KREDİLER

Günümüzde bankalar, reel büyüme için ekonomilerin işlerlik kazanmasını sağlayan bir yapı olarak sistemin vazgeçilmezleri arasında yerini almıştır. Küresel rekabet, üretim, satış ve istihdam sağlamak ülke ekonomileri için ne kadar önemli ise ülke içerisinde faaliyet gösteren kurum ve kuruluşlar için kredilere ulaşma ve etkin kullanma da aynı derecede önemlidir. Krediler sayesinde üretim, istihdam, satışlar ve tüketim artmakta ve bunların sürdürülebilir olabilmesi için kredi alma/verme şartlarının en uygun düzeyde olması gerekmektedir (Ekşi ve İkvan, 2017: 48). Tüketim malları için kitlesel pazarların ortaya çıkması ve Batılı tüketiciler tarafından yüksek yaşam standartlarına ulaşılması çoğu zaman bireysel kredilerin yaygın olarak bulunmasına bağlıdır. Bireysel krediler, kişisel finansa kısa vadeli kısıtlıya sahip tüketicilere yardımcı olmak için bankalar ve finansal kurumlar gibi borç verenler tarafından sağlanan bir tür tüketici finansmanıdır. Bireysel krediler genellikle sabit bir faiz oranından tahsil edilir ve bu oran genellikle kredi süresi veya kredi finansmanı tutarına göre derecelendirilir. Tahakkuk eden tüm faizler aylık taksitlerin bir parçası olarak ödenir ve bu aylık geri ödemeler kredi kullanım süresinin sonuna kadar devam eder (İsmail ve diğ., 2013: 587).

Bireysel krediler; ihtiyaç kredisi, konut kredisi, taşı kredisi, kredili mevduat hesabı (KMH) ve kredi kartları olarak beş madde altında kategorilendirilmiştir (Kaban, Karaca, ve Gül, 2016: 233). 2018 yılı sonu itibariyle, Türkiye ticari bankacılık sektöründe, bireysel kredi piyasası, kredi portföyünün %22 (kredi kartları %6 ve tüketici kredileri %17) 'sini oluşturan çeşitli kredi türlerinden oluşmaktadır. Krediler içinde büyük işletmelere ve projelere kullanılan kredilerin payı yüzde 53, KOBİ kredilerinin payı ise yüzde 25 olmuştur (TBB, 2019a: 24).


2018 yılında tüketici kredileri bakiyelerinin ihtiyaç, konut, taşıt ve diğer olmak üzere gruplara ayrılmış hali Şekil 1'de yer almaktadır. Bakiyeler baz alındığında bireysel krediler arasında ihtiyaç kredileri lider konumdadır (TBB, 2019b).




Şekil 2: 2018 Yılı Bireysel Kredilerin Bakiye Miktarı Dağılımı

Türkiye'de Tüketici Kredileri'ne ilişkin yıllara göre bireysel kredi bakiye tutarları ile kanuni takibe giren müşteri yüzdesine ait bilgiler Şekil 2 ve Şekil 3'te yer almaktadır. Bakiye tutarları baz alındığında 2011 yılından itibaren kanuni takibe giren müşterilerin sayısında artış meydana gelmiştir. (TBB, 2019b).

BULANIK MANTIK TEMELLİ BİREYSEL KREDİ BAŞVURUSU DEĞERLENDİRME SİSTEMİ TASARIMI



Şekil 2: Tüketici Kredilerine İlişkin Yıllık Bakiye Tutarları



Şekil 3: Bakiye Bazında Kanuni Takibe Giren Müşteri Yüzdesi

Bankalar, müşteri hakkında topladıkları tüm bilgileri, kullandıkları bir notlama sistemi üzerinden değerlendirmekte ve müşteri için bir not belirlemektedir. Bankalar, kredi değerlendirme çalışmaları sonucunda müşterilerin sahip oldukları notları temel alarak istenen şartları taşıdığına karar verilen müşterilere uygun bir teminat yapısı sağlayarak kullandırım yapmaktadır. Kredilendirme şartlarını sağlamayan müşterilerin kredi talepleri ise bankalarca reddedilmektedir (Ertaş, Kaban, ve Sobacı, 2016: 134).

3. BULANIK MANTIK

Küreselleşme süreci, finans alanında karmaşık ilişkiler ağının ortaya çıkmasına neden olmuştur. Bu durum, serbest piyasa ekonomisinde özellikle finansal kurumların durumunu etkileyen faktörlerin karmaşıklığı ve belirsizliğinin artması anlamına gelmektedir. Günümüzde finans ve ekonomi alanındaki birçok fenomen bulanıktır (Korol, 2012: 259). Finansal risk göstergelerini bulanık mantığa vurgu yaparak yorumlamak, finansal bilgilerin yorumlanmasında daha esnek bir ortamın elde edilmesine olanak sağlar (Córdova, Molina, ve López, 2017: 1688).

İnsan mantığı insanlık kadar eskidir. Sokratik diyaloglarda da görüldüğü üzere Eski Yunanistan'ın klasik metinleri mantıksal alıştırımlardır. Son yüzyıllarda ise sıkı bir matematiksel mantık oluşturulmuş olup Boole mantığı olarak kodlanmıştır. Buna ilave olarak, insanlar Boole mantığının evet / hayır yapısına tam olarak uymayan bilgileri işleyen bir mantık kullanmaktadır. Bunun modern çalışması, Lothi A. Zadeh'in 1965 yılında bulanık kümeler olarak adlandırdığı ve

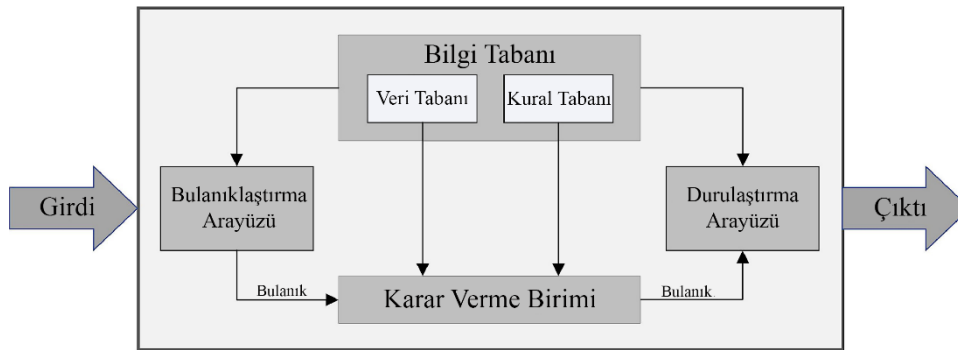
BULANIK MANTIK TEMELLİ BİREYSEL KREDİ BAŞVURUSU DEĞERLENDİRME SİSTEMİ TASARIMI

1970'li yıllarda bulanık mantık sistemine genişlettiği öncü çalışmaları ile başlamıştır (Anderson, 2004: 344).

Bulanık mantık, bazı durumları analiz etmek için kullanılmaktadır. Analiz yöntemi aşağıdaki aşamaları takip etmektedir (Mak, 2003: 21):

- Girdi verileri çok sayıda bulanık algı olarak tanımlanır.
- Girdiler, bulanık if-then kurallarının bir dizisine göre işlenir.
- Bireysel kurallardan elde edilen çıktılar kütle merkezi olarak ağırlıklandırılır ve ortalaması alınır ve tek bir çıktı kararında yoğunlaşılır.

Bulanık mantığın ardındaki teori, klasik küme teorisinin doğal bir uzantısı olan bulanık küme teorisine dayanmaktadır. Bulanık mantık, çok sayıda ve belirsiz verileri anlama, ölçme ve yönetme konusunda güçlü bir şekilde yol göstericidir. Bunlara ilave olarak bulanık mantığın ana amacı karar vermedir ve temel yapısı beş fonksiyondan oluşmaktadır. Bulanık mantığın temel yapısı Şekil 4'te gösterilmiştir (Hilletoft, Sequeira, ve Adlemo, 2019: 134-135).



Şekil 4: Bulanık Mantık Sistemi

Bulanık mantık, kontrol problemlerini çözmek için basit bir kurala dayalı "IF X AND Y THEN Z" yaklaşımını kullanır. Matematiksel olarak modellenmesi zor veya imkânsız olabilecek doğrusal olmayan sistemleri verimli bir şekilde modelleme yeteneğine sahiptir. Bulanık mantık, küçük ve basit gömülü sistemlerden büyük ve karmaşık kontrol sistemlerine, bilgi tabanlı sistemlere, görüntü işleme, enerji mühendisliği, robotik, endüstriyel otomasyon, tüketici elektroniği, çok amaçlı optimizasyon, hava tahmini, hisse senedi alım satımı, tıbbi tanı ve tedavi ve biyoinformatik ve benzeri gibi çeşitli modelleme ve kontrol uygulamaları için karar verme aşamasında iyi seçimler yapan benzersiz özellikler sunmaktadır (Raza, 2018: 190).

4. YÖNTEM

Bu bölümde finansal araştırma problemlerinden biri olan bireysel kredi onay durumu üzerine bir analiz yapılmıştır. Bu amaçla bulanık mantık kullanılmış ve dilsel terimler kullanılarak geleneksel finansal göstergelerin daha iyi yorumlanması sağlanmaya çalışılmıştır. Bulanık yöntem bilim tarafından karar verme sürecinde kullanılan bu bağlam, karar vericiye önerilen kredi derecelendirmelerinin her birine üyelik seviyelerini grafiksel olarak gözlemlemesini sağlar (Córdova ve diğ., 2017: 1688).

Sistemin geliştirilmesi için MATLAB Fuzzy Logic Designer geliştirme aracı kullanılmıştır. Çıkarım motor bilgilerinin aşağıdaki adımlardan geçmesi gerekmektedir (Jat ve Xoagub, 2016: 649):

- Adım 1: Bulanık sistem için adımların belirlenmesi,
- Adım 2: Üyelik fonksiyonunu kullanarak eklenen girdilerin bulanıklaştırılması,
- Adım 3: Kuralın gücünü elde etmek için bulanıklaştırılmış girdilerin birleştirilmesi,
- Adım 4: Kural gücünü, çıktı üyeliği ile birleştirilerek kuralın sonucunun bulunması,
- Adım 5: Çıktı dağılımını elde etmek için sonuçların birleştirilmesi,
- Adım 6: Çıktı dağılımının durulaştırılması.


BULANIK MANTIK TEMELLİ BİREYSEL KREDİ BAŞVURUSU DEĞERLENDİRME SİSTEMİ TASARIMI

Bir kredi riski belirleyicisi tasarlama sürecinde en önemli görev, öncelikle bir finansal kurumun kredi uygulamalarıyla ilgili kararına katkıda bulunan faktörleri belirlemektir. Kredi sorumlusu ile yapılan görüşme neticesinde krediye başvuran kişinin veya eşinin hacizli mal, protestolu senet ve karşılıksız çek durumu ile, krediye başvuran kişinin kredi kayıt bürosu (KKB) puanı, yaşı ve bankalara olan mevcut borç durumu olmak üzere dört ana faktör belirlenmiştir. Kredi başvuru sahiplerine ilişkin farklı parametreler ve açıklamaları Tablo 1’de yer almaktadır.

Bulanıklaştırma, girdi sayısal değerlerinin, Tablo 1’de gösterildiği gibi dilsel terimlerle temsil edilen üyelik fonksiyonlarına dönüştürülmesidir. Girdi değişkenlerinin bulanıklaştırılması için üçgen üyelik fonksiyonu kullanılmıştır. Her bir girdi değeri için üyelik fonksiyonları ise Şekil 5, Şekil 6, Şekil 7 ve Şekil 8’de detaylı bir şekilde gösterilmiştir. Çıktı değerine ilişkin üyelik fonksiyonu ise Şekil 9’da gösterilmiştir. Çıktı değerinin de bulanıklaştırılması için üçgen üyelik fonksiyonu kullanılmıştır.


Tablo 2: Girdi ve Çıktı Değerlerinin Dilsel Terimlerle Gösterimi

Girdi Değişkenleri	Dilsel Terimler	Değişkenlerin min-max Değerleri
Hacizli Mal, Protestolu Senet ve Karşılıksız Çek Durumu	Yok ([0 0 0]), Var ([1 1 1])	[0 1]
Kredi Kayıt Bürosu (KKB) Puanı	Düşük ([0 350 700]), Orta ([600 950 1300]), Yüksek ([1200 1600 2000])	[0 2000]
Yaş	Genç ([18 24 30]), Orta Yaş ([25 37 49.9]), Yaşlı ([45 70 70])	[18 70]
Bankalara Olan Mevcut Borç Durumu (bin TL)	Düşük Hacim ([2 6 10]), Orta Hacim ([8 20 32]), Yüksek Hacim ([30 50 50])	[2 50]
Çıktı Değişkenleri	Dilsel Terimler	Değişkenlerin min-max Değerleri
Kredi Onay Durumu	Krediye Uygun Değil ([0 0.05 0.1]), Düşük Ölçek Krediye Uygun ([0.0989 0.249 0.399]), Orta Ölçek Krediye Uygun ([0.25 0.5 0.75]), Yüksek Ölçekli Krediye Uygun ([0.6 0.8 1])	[0 1]




Şekil 5: Hacizli Mal, Protestolu Senet ve Karşılıksız Çek Durumu Üyelik Fonksiyonu


BULANIK MANTIK TEMELLİ BİREYSEL KREDİ BAŞVURUSU DEĞERLENDİRME SİSTEMİ TASARIMI




Şekil 6: Kredi Kayıt Bürosu (KKB) Puanı Üyelik Fonksiyonu



Şekil 7: Yaş Üyelik Fonksiyonu



Şekil 8: Bankalara Olan Mevcut Borç Durumu Üyelik Fonksiyonu



Şekil 9: Kredi Onay Durumu Üyelik Fonksiyonu

Üçüncü adımda bulanıklaştırılmış girdilerin birleştirilmesi işlemi gerçekleştirilmiştir. Dördüncü adımda ise birleştirilmiş girdilerin çıktı üyeliği ile birleştirilerek kuralın sonucu bulunmuştur. Öncelikle 4 adet giriş değişkeni ile 1 adet çıkış değişkeninin dilsel terimleri dikkate

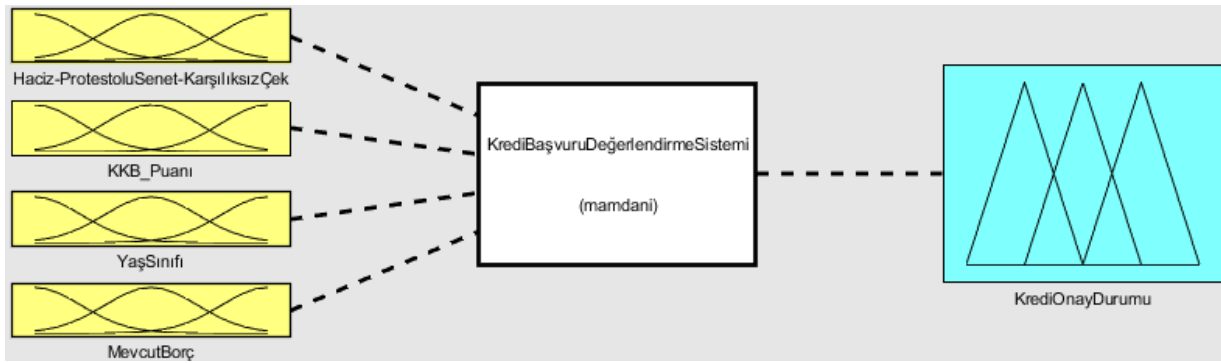
BULANIK MANTIK TEMELLİ BİREYSEL KREDİ BAŞVURUSU DEĞERLENDİRME SİSTEMİ TASARIMI

alınarak hangi durumlarda başvurunun reddedilmesi ve hangi durumlarda ölçeğine göre başvurunun kabul edilmesi kararını vermek için 54 adet kural oluşturulmuştur. Şekil 10'da kural setine dair bir örnek yer almaktadır.

33. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is düşük) and (YaşSınıfı is OrtaYaş) and (MevcutBorç is Yüksek) then (KrediOnayDurumu is KrediyeygunDeğil) (1)
34. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is düşük) and (YaşSınıfı is Yaşlı) and (MevcutBorç is Düşük) then (KrediOnayDurumu is KrediyeygunDeğil) (1)
35. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is düşük) and (YaşSınıfı is Yaşlı) and (MevcutBorç is Orta) then (KrediOnayDurumu is KrediyeygunDeğil) (1)
36. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is düşük) and (YaşSınıfı is Yaşlı) and (MevcutBorç is Yüksek) then (KrediOnayDurumu is KrediyeygunDeğil) (1)
37. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is orta) and (YaşSınıfı is Genç) and (MevcutBorç is Düşük) then (KrediOnayDurumu is OrtaÖlçek) (1)
38. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is orta) and (YaşSınıfı is Genç) and (MevcutBorç is Orta) then (KrediOnayDurumu is DüşükÖlçek) (1)
39. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is orta) and (YaşSınıfı is Yaşlı) and (MevcutBorç is Yüksek) then (KrediOnayDurumu is DüşükÖlçek) (1)
40. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is orta) and (YaşSınıfı is OrtaYaş) and (MevcutBorç is Düşük) then (KrediOnayDurumu is OrtaÖlçek) (1)
41. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is orta) and (YaşSınıfı is OrtaYaş) and (MevcutBorç is Orta) then (KrediOnayDurumu is OrtaÖlçek) (1)
42. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is orta) and (YaşSınıfı is OrtaYaş) and (MevcutBorç is Yüksek) then (KrediOnayDurumu is DüşükÖlçek) (1)
43. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is orta) and (YaşSınıfı is Yaşlı) and (MevcutBorç is Düşük) then (KrediOnayDurumu is YüksekÖlçek) (1)
44. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is orta) and (YaşSınıfı is Yaşlı) and (MevcutBorç is Orta) then (KrediOnayDurumu is OrtaÖlçek) (1)
45. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is orta) and (YaşSınıfı is Yaşlı) and (MevcutBorç is Yüksek) then (KrediOnayDurumu is DüşükÖlçek) (1)
46. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is yüksek) and (YaşSınıfı is Genç) and (MevcutBorç is Düşük) then (KrediOnayDurumu is YüksekÖlçek) (1)
47. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is yüksek) and (YaşSınıfı is Genç) and (MevcutBorç is Orta) then (KrediOnayDurumu is OrtaÖlçek) (1)
48. If (Haciz-ProtestoluSenet-KarşılıksızÇek is yok) and (KKB_Puani is yüksek) and (YaşSınıfı is Genç) and (MevcutBorç is Yüksek) then (KrediOnayDurumu is DüşükÖlçek) (1)

Şekil 10: Kredi Onay Durumu Üyelik Fonksiyonu

Ele alınan çalışmada Mamdani tipi bulanık çıkarım yöntemi kullanılmıştır. Mamdani bulanık çıkarım yöntemi ile oluşturulan bulanık mantık sistem tasarımı ise Şekil 11'de gösterilmiştir.



Şekil 11: Tasarlanan Bulanık Mantık Sistemi

Çalışmada, durulaştırma işlemi, hesaplama süresi kısa olduğu için tüm durulaştırma yöntemlerinin en yaygın ve en cazibi olarak kabul edilen centroid yöntemi kullanılarak birleştirilmiş fonksiyonu net değerler olarak verilmiştir (Bennouna ve Tkiouat, 2018: 278).

Tasarlanan bulanık mantık sisteminin sınanma işlemi, beş başvuru sahibinden oluşan bir örnek olay yardımıyla gerçekleştirilmiş olup Tablo 2'de özetlenmiştir. Elde edilen bulgular bankada kredi verme alanında hizmet veren uzmanın kararlarıyla örtüşmektedir.

Tablo 2: Örnek Olay

Başvuru Sahipleri	Hacizli Mal, Protestolu Senet ve Karşılıksız Çek Durumu	Kredi Kayıt Bürosu (KKB) Puanı	Yaş	Bankalara Olan Borç Durumu	Bulanık Karar	Önerilen Karar
BS1	Yok (0)	Orta (800)	Genç (23)	Orta Hacim (28)	0,25	Düşük Ölçek Krediyeye Uygun
BS2	Yok (0)	Düşük (500)	Orta Yaş (50)	Orta Hacim (15)	0,05	Krediyeye Uygun Değil
BS3	Yok (0)	Orta (900)	Orta Yaş (40)	Düşük Hacim (3)	0,5	Orta Ölçek Krediyeye Uygun
BS4	Var (1)	Yüksek (1700)	Genç (19)	Düşük Hacim (7)	0,05	Krediyeye Uygun Değil
BS5	Yok (0)	Yüksek (1950)	Yaşlı (58)	Orta Hacim (14)	0,8	Yüksek Ölçek Krediyeye Uygun

BULANIK MANTIK TEMELLİ BİREYSEL KREDİ BAŞVURUSU DEĞERLENDİRME SİSTEMİ TASARIMI

5. SONUÇLAR

Hızlı, daha kesin, kısmen veya tamamen otomatikleştirilmiş karar verme sistemleri, günümüzde çeşitli yazılımlar yardımıyla kolaylıkla geliştirilebilmektedir. Bu karar verme sistemleri yardımıyla, zamandan tasarruf edilmekte, yanlış verilen kararlarda azalma meydana gelmekte ve işletme giderlerinden tasarruf edilerek toplam maliyette azalmaya gidilmektedir. Bu durum, firmaların başarılı bir şekilde rekabet etmelerine yardımcı olacaktır (Chen, Kaboudan, ve Du, 2018: 390).

Bu çalışmanın amacı, bulanık mantığı kullanarak müşteri bilgilerine dayanarak müşteri davranışını tahmin edebilecek bir kredi onay durumu modeli oluşturmaktır. Bulanık mantık yöntemi, yalnızca istatistiksel çalışmalara değil aynı zamanda müşterilerle direkt olarak temas halinde olan banka yetkilisinin görüşüne de değinerek müşteri davranışı hakkında öngörü sağlar. Bulanık bilgi tabanı, farklı senaryolarla başa çıkma konusunda uzman bilgisi yakalamak için geliştirilmiştir. Bu bulanık bilgi tabanı, kredi başvurusu onay sürecinde bankalar için bir uzman gibi destek olacaktır.

Çalışmada MATLAB Fuzzy Logic Designer geliştirme aracı kullanılarak geliştirilen bulanık mantık sisteminin basit ve anlaması oldukça kolaydır. Bu kolaylığın ortaya konulması için beş değişik kredi başvurusunun onay veya red sonucu ile sonuçlandırılması hakkında bir örnek olay çalışması geliştirilmiştir.

Belirli girdilerin sınıflandırılması zamanla değişebilir olduğundan bunların zamanla güncellenmesi ve gerekli durumlarda da yeni girdilerin sisteme eklenmesi gereklidir. Bunun yanı sıra bulanık mantık yönteminin finans alanında uygulama sayısının ve çeşitliliğinin gün geçtikçe artması, ayrıca bu yöntemi kullanan araştırmacıların ve bu araştırmacıları çatıları altında barındıran kurumların sayısının artması yöntemin gelecekteki yıllarda daha da etkin bir forma kavuşacağını göstermektedir.

6. KAYNAKÇA

Anderson, P. L. (2004). Business economics and finance with MATLAB, GIS, and simulation models: Chapman and Hall/CRC.

Antwi, S., Atta Mills, E. F. E., Atta Mills, G., ve Zhao, X. (2012). Risk factors of loan default payment in Ghana: a case study of Akuapem Rural Bank. *International Journal of Academic Research in Accounting, Finance Management Sciences*, 2(4), 376-386.

Baesens, B., Van Gestel, T., Stepanova, M., Van den Poel, D., ve Vanthienen, J. (2005). Neural network survival analysis for personal loan data. *Journal of the Operational Research Society*, 56(9), 1089-1098. doi:<https://doi.org/10.1057/palgrave.jors.2601990>

Bennouna, G., ve Tkiouat, M. (2018). Fuzzy logic approach applied to credit scoring for microfinance in Morocco. *Procedia Computer Science*, 127, 274-283. doi:<https://doi.org/10.1016/j.procs.2018.01.123>

Chen, S.-H., Kaboudan, M., ve Du, Y.-R. (2018). *The Oxford handbook of computational economics and finance*: Oxford University Press.

Córdova, J. F. D., Molina, E. C., ve López, P. N. (2017). Fuzzy logic and financial risk. A proposed classification of financial risk to the cooperative sector. *Contaduría y Administración*, 62, 1687-1703. doi:<https://doi.org/10.1016/j.cya.2017.10.001>

Ekşi, İ. H., ve İkvan, A. (2017). İşletmelerin finansmanında mevduat bankalarının kredi arz davranışları. *Yönetim ve Ekonomi Araştırmaları Dergisi*, 15(2), 47-61. doi:<http://dx.doi.org/10.11611/yead.312806>

Ertaş, F. C., Kaban, İ., ve Sobacı, F. (2016). Bireysel kredi kullanan finansal tüketicilerce üstlenilen masraflar; BDDK düzenlemesi çerçevesinde karşılaştırmalı bir değerlendirme. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 8(14), 125-146. doi:10.14784/jfrs.21124

BULANIK MANTIK TEMELLİ BİREYSEL KREDİ BAŞVURUSU DEĞERLENDİRME SİSTEMİ TASARIMI

Hilletofth, P., Sequeira, M., ve Adlemo, A. (2019). Three novel fuzzy logic concepts applied to reshoring decision-making. *Expert Systems with Applications*, 126, 133-143. doi:<https://doi.org/10.1016/j.eswa.2019.02.018>

Ismail, S., Othman, R., Kamalrulzaman, S. N. H., Jahya, A., Idris, N. H., Zaitun, S., ve Izren, F. (2013). Determinants of Personal Loans Borrowing: An Empirical Study. Paper presented at the Symposium on Business, Engineering and Industrial Applications.

Jat, D. S., ve Xoagub, A. J. (2016). Fuzzy logic-based expert system for assessment of bank loan applications in Namibia. Paper presented at the International Congress on Information and Communication Technology (ICICT 2015).

Kaban, İ., Karaca, S. S., ve Gül, M. (2016). Bireysel müşteriler ve bankalar arasındaki ilişkilerde yeni dönem: Tüketici kredisi sözleşmeleri yönetmeliği üzerine bir değerlendirme. *Yönetim ve Ekonomi Araştırmaları Dergisi*, 14(1), 227-247. doi:<http://dx.doi.org/10.11611/JMER778>

Kamleitner, B., ve Kirchler, E. (2006). Personal loan users' mental integration of payment and consumption. *Marketing Letters*, 17(4), 281-294. doi:<https://doi.org/10.1007/s11002-006-8521-9>

Korol, T. (2012). Fuzzy logic in financial management. In E. P. Dadios (Ed.), *Fuzzy logic-emerging technologies and applications* (ss. 259-286): InTechOPEN.

Mak, D. K. (2003). *The science of financial market trading*: World Scientific.

Raza, K. (2018). Fuzzy logic based approaches for gene regulatory network inference. *Artificial Intelligence in Medicine*, 97, 189-203. doi:<https://doi.org/10.1016/j.artmed.2018.12.004>

TBB. (2019a). Faaliyet Raporu 2018-2019. Retrieved from https://www.tbb.org.tr/Content/Upload/Dokuman/7598/Faaliyet_Raporu_2018-2019.pdf

TBB. (2019b). Tüketici kredileri ve konut kredileri. https://www.tbb.org.tr/Content/Upload/istatistikraporlar/ekler/1158/1.Tuketici_Kredileri-1997-2018_Yil_sonlari.xls

Tsai, M.-C., Lin, S.-P., Cheng, C.-C., ve Lin, Y.-P. (2009). The consumer loan default predicting model—An application of DEA—DA and neural network. *Expert Systems with applications*, 36(9), 11682-11690. doi:<https://doi.org/10.1016/j.eswa.2009.03.009>

Wang, M.-C., Chen, S.-S., ve Chiang, J.-M. (2017). Rationality of the personal loan interest-rate markups of banks. *Corporate Management Review*, 37(1), 115-163.

Zhang, Z. (2011). Research of default risk of commercial bank's personal loan based on rough sets and neural network. Paper presented at the 2011 3rd International Workshop on Intelligent Systems and Applications, Wuhan, China.