



Seramik Sağlık Gereçleri Ürünlerinin Makine Öğrenmesi Yöntemleriyle Kalite Sınıflandırması

Quality Classification of Ceramic Sanitary Ware Products with Machine Learning Algorithms

Sedanur ŞİMŞEK¹, Erdener ÖZÇETİN²

¹Hitit Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Çorum
· sedanursimsek3@gmail.com · ORCID > 0009-0001-0230-955X

²Hitit Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Çorum
· erdenerozctin@hitit.edu.tr · ORCID > 0000-0002-6079-3159

Makale Bilgisi/Article Information

Makale Türü/Article Types: Araştırma Makalesi/Research Article

Geliş Tarihi/Received: 10 Şubat/February 2024

Kabul Tarihi/Accepted: 26 Mart/March 2024

Yıl/Year: 2024 | **Cilt-Volume:** 4 | **Sayı-Issue:** 1 | **Sayfa/Pages:** 35-47

Atıf/Cite as: Şimşek, S., Özçetin, E. "Seramik Sağlık Gereçleri Ürünlerinin Makine Öğrenmesi Yöntemleriyle Kalite Sınıflandırması" Ondokuz Mayıs Üniversitesi Mühendislik Bilimleri ve Teknolojisi Dergisi 4(1), Mart 2024: 35-47.

Sorumlu Yazar/Corresponding Author: Erdener ÖZÇETİN

SERAMİK SAĞLIK GEREÇLERİ ÜRÜNLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE KALİTE SINIFLANDIRMASI

ÖZ

Endüstride geniş bir yelpazeye sahip olan seramik sağlık gereçleri, yüksek sıcaklık dayanımı, yüksek sertlik ve korozyon direnci gibi özellikleri nedeniyle öne çıkar. Ancak, üretim sürecinde birçok faktörün etkisi söz konusu olduğundan, seramik sağlık gereçlerinin kalite kontrolü yönetim açısından zorlayıcı olabilmektedir. Makine öğrenmesi yöntemleri ise sınıflandırma ve tahmin problemlerini çözmede etkin bir şekilde kullanılmaktadır. Bu çalışmada, Türkiye'de faaliyet gösteren büyük ölçekli bir seramik sağlık gereçleri üretim tesisi verilerini kullanarak ürün kalitesinin sınıflandırılmasına odaklanılmıştır. Gerçek hayatta karşılaşılan bu problemde, kalite açısından iki farklı sınıf bulunmaktadır. İki sınıflı bu problem için çeşitli makine öğrenimi yöntemleri kullanılarak modeller oluşturulmuş ve elde edilen sonuçlar üzerine detaylı tartışmalar yürütülmüştür. Buna göre doğruluk değeri en yüksek model 0.87 ile karar ağaçları modeli olmuştur. Gini indeksiyle hesaplanan model doğruluk puanı ise 0.864'tür.

Anahtar Kelimeler: Seramik Sağlık Gereçleri, Makine Öğrenmesi, Kalite Kontrol, Sınıflandırma.



QUALITY CLASSIFICATION OF CERAMIC SANITARY WARE PRODUCTS WITH MACHINE LEARNING ALGORITHMS

ABSTRACT

Ceramic products have a wide range of applications in industry due to their properties such as high temperature resistance, high hardness and corrosion resistance. On the other hand, many factors are involved in the production process of ceramic products and managing the quality control process can be challenging. Machine learning methods are widely used in classification and regression problems. In this study, we focus on the quality classification of products using data from a large-scale ceramic sanitary ware production facility. For this real-life problem, there are two classes in terms of quality depending on the data used. For the two-class problem, several machine learning methods were used to build models and discussions were made on the results

obtained. Accordingly, the model with the highest accuracy value is the decision tree model with 0.87. In addition, the model accuracy score calculated with the Gini Index is 0.864.

Keywords: Ceramic Sanitary Ware Products, Machine Learning, Quality Control, Classification.

Öne Çıkanlar

Çalışmada üretim sonrası seramik sağlık gereçlerinin sınıflandırma problemi çeşitli makine öğrenmesi algoritmalarıyla ele alınmaktadır.



1. GİRİŞ

Türkiye seramik sağlık gereçleri bakımından önemli üretim tesislerinin bulunduğu bir ülkedir. Bu bakış açısından üretilen ürünlerin kalite sınıflandırılmasının etkin bir şekilde gerçekleştirilmesi büyük önem taşımaktadır. Makine öğrenmesi yöntemleri seramik ürünleri kalite bakımından sınıflandırmak için etkin bir araç olarak kullanılabilir. İyi bir sınıflandırma modeli kurabilmek için probleme ait özelliklerin doğru seçilmesi gerekmektedir. Bu üretim sürecinin içerisindeki çeşitli parametrelerin ve kalite kontrol verilerinin kurumsal kaynak planlaması yazılımlarının kayıtları ve işletmelerdeki tecrübeli personellerle gerçekleştirilebilir. Seramik ürünlerin kalitesinin sınıflandırılmasında kullanılacak makine öğrenmesi yöntemleri arasında lojistik regresyon, karar ağaçları, destek vektör makineleri ve yapay sinir ağları gibi çeşitli yöntemler bulunmaktadır. Makine öğrenmesi yöntemleri kullanılarak seramik ürünlerin kalitesinin sınıflandırılması ya da tahminine yönelik olarak literatürde çeşitli çalışmalar bulunmaktadır. Ramesh ve ark. [1] seramik ürünlerin kalitesini tahmin etmek için destek vektör makineleri kullanarak regresyon modeli geliştirmişlerdir. Nan Qu ve ark. [2] seramik ürünlerinin kalitesinin tahmininde kullanılacak makine öğrenmesi modellerinden biri olan yapay sinir ağları oluşturulmuştur. Çalışmada çok katmanlı yapay sinir ağı modeli önerilmiş ve sonuçlar karşılaştırılarak tartışılmıştır. Seramik ürünlerin kalitesinin tahmini için rastgele ormanlar, bagging ya da boosting gibi topluluk modelleri de kullanılabilir. Yicong Ye ark. [3] çalışmasında farklı makine öğrenmesi yöntemleri ve topluluk modellerini kullanarak seramik ürünlerin kalite tahmini üzerinde durmuş ve karşılaştırmalar gerçekleştirmişlerdir. Tao Chen ve ark. [4] çalışmasında Taguchi yöntemini kullanarak varyans analizi gerçekleştirerek özellikleri önem sırasına göre seçmişlerdir. Buna bağlı olarak seçilen özelliklerle bir destek vektör makineleri modeli oluşturmuşlardır. Son zamanlarda yapılan çalışmalardan birinde Çöpöğlü ve ark. [5], seramik sağlık gereçleri sektö-

ründe faaliyet gösteren bir firmanın duş teknesi ürünleri için ürün boyutlarının ölçümü için bilgisayarlı görü yöntemlerinden faydalanmıştır. Bir diğer çalışmada Cao ve ark. [6], seramik karoların hata tespiti için çok ölçekli özellikler ve sınıf dengesizliği ile ilgili zorlukları etkili bir şekilde ele almak için tasarlanmış yeni bir ağ mimarisi önermişlerdir. Wan ve ark.[7] ise, yine seramik karolarda hata tespiti için derin öğrenme temelli modeller oluşturmuştur. Zhang ve ark. [8], pürüzlü seramik yüzeylerden görüntü işleme yöntemleriyle hata tespiti için yeni bir yaklaşım üzerinde durmuşlardır. Lu ve ark. [9], yüksek çözünürlüklü seramik karo görüntülerinin küçük yüzey kusurlarının tespiti için bir algoritma önermişlerdir.

Çalışmada ülkemizde büyük ölçüde üretim gerçekleştiren bir seramik sağlık gereçleri tesisinin gerçek hayat verileri kullanılmıştır. Firmanın kurumsal kaynak planlaması sisteminden elde edilen veriler ve öznitelikler kurulan modellerin girdisi olarak kullanılmıştır. Lojistik regresyon, destek vektör makineleri ve karar ağaçları makine öğrenmesi yöntemleri için modeller kurulmuş ve karşılaştırmalı olarak tartışılmıştır. Çalışmanın ikinci bölümünde seramik sağlık gereçlerinin genel proses süreçleri ve kullanılan öznitelikler aktarılmaktadır. Üçüncü bölümde kullanılan makine öğrenmesi yöntemleri ve metrikler ile ilgili bilgiler verilmektedir. Dördüncü bölümde sonuçlar ve tartışmalara değinilmektedir. Beşinci bölümde ise çalışmanın değerlendirilmesi ve gelecek çalışmalar hakkında bir tutum ortaya konulmaktadır.

2. MATERYAL VE YÖNTEMLER

Seramik, çeşitli maddelerin birleştirilmesiyle çeşitli işlemler gören malzemedir. Seramik, genellikle kil, feldspat, çamur, kuvars ve talk minerallerinin suyla karıştırılmasıyla üretilen nesnelere dir. Korozyona karşı güçlü, sert, bir malzemedir. Seramikler yapısal olarak kırılabilir, sert ve düşük esnek bir yapıya sahiptirler. Yüksek sertlikleri sebebiyle çok tok malzeme olarak kabul edilir. Darbeye, kırılmaya karşı dayanıklı ve deformasyon göstermezler. Bu özellikler sebebiyle, seramik ürünler yüksek sıcaklık ortamında ve yüksek basınç altında işlem görerek üretilirler. Seramik ürünler tasarlanırken optimum esneklik ve optimum dayanıklılık arasındaki denge sağlanarak üretilmelidir [10].

Seramik ürünler işlem gördüğü sıcaklığa ve üretimde kullanılan malzemelere göre farklı özelliklere sahip olabilmektedirler. Düşük sıcaklıkta işlem gören seramik ürünler genellikle daha kırılabilir ve su emici ürünlerdir. Yüksek sıcaklıkta işlem gören seramik ürünler daha dayanıklı ve daha az su emicilerdir. Seramiklerin kullanım alanları oldukça geniştir. Örneğin, sağlık gereçleri sektöründe pisuvar, klozet, duş teknesi, bide, lavabo gibi vitrifiye ürünler üretilmektedir. Porselen, seramik fayanslar, piezoelektrik seramikler, kalça protezi, yapay diş, fren diskleri, heykel, çömlek, endüstriyel yüzeyler gibi birçok endüstriyel uygulamalarda kullanılmak-

tadır [11]. Seramik ürünlerin döküm çamurunda iki tip çeşit çamur kullanılmaktadır. VC (Vitreous China) ve FFC (Fine Fire Clay) 'dir [12]. VC çamuru kireç, düşük alkali, doğal kil ve feldspat karışımından üretilmektedir. VC çamuru su emmeyen, dayanıklı seramikler üretmek amacıyla yüksek sıcaklıkta sinterleme işlemi yapılır. VC çamuru klozetler, lavabolar, hela taşı, banyo armatürleri gibi ürünlerin üretiminde sıklıkla kullanılmaktadır. FFC çamuru kireç, kil, feldspat ve yüksek alkali karışımından üretilmektedir. FFC çamuru su emme özelliği VC çamuruna göre daha yüksek ancak dayanıklılığı daha azdır. VC çamuru gibi FFC çamuru da yüksek sıcaklıklarda sinterleme işlemi görmektedir. FFC çamuru porselen, karo, fayans gibi daha ince ve daha estetik ürünlerin üretiminde kullanılmaktadır [13]. İki çamur türü de seramik sektöründeki ürünlerin üretiminde geniş bir kullanım alanına sahiptir. Şekil 1'de bir seramik sağlık gereci ürününün genel hatlarıyla üretim aşamaları görülmektedir.



Şekil 1. Temel seramik üretim prosesi

Seramik ürünlerin üretim sürecinin ana prosesleri şöyledir; ilk işlem hammadde hazırlama prosesidir. Ürünün üretimi için özel olarak seçilmiş olan mineraller kullanılır. Daha önceden belirlenmiş oranlarda hammaddeler karıştırılır ve işlem görebilecek uygun hale getirilir. Uygun hale getirilen hammadde uygun kalıplara konularak basınç yardımıyla bastırılıp şekillendirme prosesine hazır hale getirilir. Şekillendirme aşamasında, hammadde kalıptan çıkarıldıktan sonra gerekli aletler süngerler yardımıyla şekillendirilir. Kurutma prosesinde, şekillendirilmiş parça kurutma işleminin yapılması için uygun olan bir alanda kurutmaya bırakılır. Kurutma yapılmasının amacı ürünlerdeki nemin kaybolmasını sağlamaktır. Sırlama prosesinde, ürünün üzerine camsı bir tabaka uygulanır. Bu işlemin amacı seramik ürünleri korumak, estetik görünümünü kazandırılmasını ve hijyenik olması amacıyla yapılmaktadır. Pişirme prosesinde, kurutulmuş olan ürün yüksek sıcakta pişirilerek sertleşmesi sağlanır. Pişirilmesinin amacı ürünün dayanıklı ve sağlam olmasını sağlamaktır. Mamul sürecinde ise ürünün gerekli parçaları birleştirip montajı yapılır. Ürünün paketlenmesini, sevkiyata hazır hale getirilmesini sağlar [14].

Seramikte ürün kalitesi, ürünün estetik görünümü, malzemenin dayanıklılığı, üretim teknolojisi, teknik özellikleri, boyutlar ve şekiller gibi diğer tüm özelliklerin bir arada değerlendirilmesiyle belirlenen özelliktir. Ürünün kalitesi tasarımdan son kullanıcının kullanımına kadar birçok faktörden etkilenmektedir.

Giuseppe Cultrone ve Fatma Madkour çalışmalarında [15] ısıl işlemlerin seramik ürününün kalitesinde önemli bir faktör olduğu ortaya atılmaktadır. Malzemenin dayanıklılığı, ürün kalitesinin en önemli faktörlerinden birisidir. Seramik ürün-

ler darbelere, ısıl işlemlere, korozyona, kimyasal işlemlere maruz kalmaktadırlar. Bu nedenle seramik ürünlerinin dayanıklılığı, uzun ömürlü olmasını ve müşterinin kullanımı sırasında hasar oluşturma riskini azaltır. Estetik görünüm, seramik ürünlerin kalitesini etkileyen bir diğer faktördür. Seramik ürünler dekoratif bir nedenle kullanılabilir veya bir alanın görünümünü oluşturabilir. Seramik ürünlerin estetik kalitesi, yüzey, desen, renk ve parlaklık gibi faktörlere bağlıdır. Seramik ürünlerin estetik kalitesi müşterinin ihtiyaçlarına ve zevkine uygun olmalıdır. Seramik ürünlerin boyutları, işlevi ve diğer teknik özellikleri de ürün kalitesini etkiler. Seramiklerin doğru boyutlarda ve doğru şekilde üretilmesi, müşterilerin ihtiyaçlarını karşılamalarına yardımcı olur. Seramik ürünlerin üretimi sürecinde kullanılan teknoloji ve kalite kontrol önlemleri ürünün kalitesini belirlenmesine yardımcı olmaktadır. Geleneksel kalite kontrol yöntemi, seramik ürünlerin üretimi esnasında yüzey kusurlarına manuel olarak tespit edilmesini ve ürünlerin kalitelerine göre ayrıştırılmasıyla uygulanmaktadır. Fakat bu yöntemin yanılma payı yüksek olmakta ve yüzey kusurları detaylı olarak anlaşılmemektedir. Bu da üretim maliyetleri açısından olumsuz sonuçlar oluşturabilmektedir. Bu nedenle kalite standartlarına uygun olarak yüzey kalitesini belirlemek için görüntü işleme alanında sıkça kullanılan filtreleme yöntemleri şunlardır; Gauss, Median, Wiener, Gabor ve Steerable Digital filtreleme yöntemleridir. Yüzey kusurları sınıflandırılması için derin öğrenme tabanlı yöntemlerden de yararlanılabilmektedir. Coşkun ve ark. [16] ürünlerin kalite açısından yanlış sınıflandırmalarını önlemek için Wiener filtreleme yöntemlerine dayalı derin öğrenme modeli önermişlerdir. Seramik ürünlerin kalite aşamaları girdi kontrolü, üretim öncesi kalite kontrolü, üretim aşamasında kalite kontrolü, son ürün kalite kontrolü ve paketleme kalite kontrolü aşamalarından oluşmaktadır.

Seramikler ürünler, sert ve kırılğan yapıları sebebiyle üretim, montaj ve kullanım sırasında çatlaklar, delikler, yüzey kusurları, fonksiyonel hatalar gibi kalite problemlerine karşı hassastırlar. Bu nedenle, seramik ürünlerin kalite kontrolü için farklı muayene ve test yöntemleri kullanılmaktadır. Bu yöntemlerden biri de Non-Destructive Testing (NDT) yöntemidir.

NDT, seramik malzemelerin kalitesini ve özelliklerini belirlemek için kullanılan test ve muayene yöntemlerinden biridir. NDT yöntemi, malzemelerin iç ve dış yüzeylerindeki hataları ve diğer kalite problemlerini tespit eder ve seramik malzemelerin hasar görmesine ve deformasyona sebep olmadan sağlıklı bir şekilde test edilmesini sağlar. Bu yöntem seramik endüstrisinde yaygın olarak kullanılan bir kalite kontrol yöntemidir. NDT yöntemleri farklı ilkeler üzerine kurulmuştur ve farklı sonuçlar elde edilebilmektedir. Yaygın olarak kullanılan NDT yöntemleri şunlardır; ultrasonik test, röntgen testi, termal test, manyetik test, optik test, X-ışını testi, sıvı penetrant testleridir. Zhike Zhao çalışmasında seramik ürünlerin kalitesini kontrol test ve muayenesini gerçekleştirmek için NDT yöntemlerini kullanmıştır. Çalışmada makine görüşü ve lazer ultrasonik teste odaklanılmıştır [17].


Bu çalışmada makine öğrenmesi modellerinde girdi verisi olarak kullanılmak üzere bir tür klozete ait olan üç aylık veri kurumsal kaynak planlaması yapılımlından temin edilmiştir. Buna göre modellerde kullanılan öznitelikler Tablo 1'de görülmektedir.

Tablo 1. Kullanılan öznitelikler

Öznitelik	Açıklama
Fırın Adı (A)	Fırın4, Fırın5, Fırın6, Tünel Fırın
Sıcak Tamir (B)	0(Tamir Görmedi), 1(Tamir Gördü)
Soğuk Tamir (C)	0(Tamir Görmedi), 1(Tamir Gördü)
Personel (D)	13 Farklı Personel
Hata Kodu (E)	24 Farklı Hata Kodu
Rötuşcu (F)	43 Farklı Rötuşcu
Sırcı (G)	35 Farklı Sırcı
Sırcı Kabini (H)	11 Farklı Sırcı Kabini
Vagon (I)	5 Farklı Vagon
Vakum (J)	0 (Hayır), 1 (Evet)
Kalite (Y)	AA (1.Kalite), A. (2.Kalite)

Makine öğrenmesi, seramik ürünlerin kalitesini sınıflandırmak için güçlü bir araç olarak kullanılmaktadır. Üretim sürecinin içerisindeki çeşitli parametrelerin isabetli tercih edilmesi ve verilerin sağlıklı bir şekilde toplanması kalite sınıflandırması açısından önem arz etmektedir. Çalışmada literatürde etkinliği kanıtlanan yöntemlerden lojistik regresyon, destek vektör makineleri ve karar ağaçları yöntemleri kullanılmıştır.

Destek vektör makineleri yöntemi, regresyon ve sınıflandırma problemlerinde kullanılan güçlü bir makine öğrenimi araçlarından biridir. Destek vektör makineleri yöntemi, veri noktalarını farklı sınıflara ayırmak için Şekil 2'deki gibi bir hiperdüzlem oluşturur [18]. Bu hiperdüzlem oluşturulurken iki sınıfının noktaları için de maksimum uzaklıkta olmasını amaçlanır. Bu yöntem yüksek boyutlu veri setlerinde etkili bir şekilde çalışabilmektedir. Avantajları arasında yüksek ve küçük boyutlu veri setlerinde iyi bir performans göstermesi ve çoklu sınıf sınıflandırılması için de kullanılabilmesi yer almaktadır. En önemli dezavantajı ise parametrelerinin ayarlanmasının zorluğudur. Bununla beraber özellikle büyük veri setlerindeki zaman ve hafıza açısından sorun oluşturabilmektedir [19].



Şekil 2. Destek vektör makineleri çalışma prensibi

Karar ağaçları yöntemi, regresyon ve sınıflandırma problemlerinde kullanılan bir makine öğrenmesi yöntemidir [20]. Bu yöntem, veri setindeki ilişkileri ve desenleri tanımlayan bir ağaç yapısı oluşturmaktadır. Diğer bir deyişle larar ağaçları, veri kümesindeki özellikleri (features) değerlendirerek bir dizi kararla sonuca ulaşır. Her iç düğüm (node) bir özellik testini temsil eder ve her yaprak düğüm (leaf node) bir sınıfı veya sınıfın bir tahminini belirtir. Karar ağaçları, veri setini rekürsif olarak bölerek her düğümde en iyi bölünmeyi (en homojen alt küme) bulmaya çalışır. Bu bölünme, veri setini mümkün olduğunca homojen alt gruplara ayırarak sınıfları en iyi şekilde ayırmayı amaçlar. Bu yöntem, veri setindeki özelliklerin önemini belirler ve karmaşık kararları basit kararlarla birleştirmesine katkı sağlamaktadır. Yöntemin avantajları arasında sonuçların anlaşılabilir, yorumlanabilir olması ve eksik ya da gürültülü veri setleri ile başa çıkabilmesi yer almaktadır. Dezavantajlarından en temeli aşırı öğrenme (over fitting) sorunu yaşayabilmektedirler. Bazı durumlarda da karmaşık ilişkileri modellemekte zorlukla karşılaşabilmektedir [21].

Lojistik regresyon yöntemi, sınıflandırma yöntemi olarak kullanılan istatistiksel bir modeldir. Bağımlı değişkenin bir ya da daha fazla bağımsız değişkenle ilişkisini tahmin etmek amacıyla kullanılmaktadır. Lojistik regresyon, doğrusal regresyonun bir genelleştirmesidir. Ancak, çıktıyı doğrusal olmayan bir fonksiyonla

sınırlar (sigmoid fonksiyonu veya lojistik fonksiyon). Bu sayede, lojistik regresyon çıktısı $[0, 1]$ aralığında tahmin eder, bu da olasılık değerlerini temsil eder. Yöntemin avantajları arasından sonuçlarının yorumlanmasının kolay olması, hızlı uygulanabilir olması ve hesaplama açısından maliyetinin düşük olması yer almaktadır. Dezavantajı ise lineer bir model olmasından dolayı karmaşık ilişkileri modellemede sınırlı kalmasıdır [22].

Çalışmada model başarısının tutarlılığı açısından öncelikle olarak bir veri ölçeklendirme işlemi yapılmıştır. Burada kullanılan yöntem aşağıdaki formüldeki gibi min-max ölçeklendirilmesidir.

$$x_{\text{ölçekli}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (1)$$

Model başarısını ölçmek için literatürde sıklıkla kullanılan yöntemlerden faydalanılmıştır. Bunlar sırasıyla doğruluk, duyarlılık, kesinlik ve F1 skorudur. Bu metriklerin hesaplanmasında Tablo 2'de verilen değerler kullanılmaktadır.

Tablo 2. Hata matrisi

Tahmin/Gerçek	Pozitif	Negatif
Pozitif	a	c
Negatif	b	d

Gerçek Pozitif (a): Gerçek pozitiflerin doğru bir şekilde tahmin edildiği sayı.

Yanlış Negatif (b): Gerçek pozitiflerin yanlışlıkla negatif olarak tahmin edildiği sayı.

Yanlış Pozitif (c): Gerçek negatiflerin yanlışlıkla pozitif olarak tahmin edildiği sayı.

Gerçek Negatif (d): Gerçek negatiflerin doğru bir şekilde tahmin edildiği sayı

Doğruluk:

Bir sınıflandırma modelinin başarısının ölçülmesinde kullanılan en basit yöntemdir. Doğru tahmin edilen örnek sayısının toplam örnek sayısına oranıdır. Doğru tahminlerin yüzdesini ifade eder. Modele ait doğruluk oranı hesaplanmaktadır.

$$\text{Doğruluk} = \frac{a + d}{a + b + c + d} \quad (2)$$

Duyarlılık:

Gerçek pozitif sayısının, gerçek pozitif ve yanlış negatif sayılarının toplamına oranını ifade eder. Duyarlılık, yanlış negatiflerin ne kadar az olduğunu ölçer ve bir modelin ne kadar iyi pozitif örnekleri tespit ettiğini gösterir.

$$Duyarlılık = \frac{a}{a + b} \quad (3)$$

Kesinlik:

Kesinlik, gerçek pozitif sayısının gerçek pozitif ve yanlış pozitif sayıların oranını ifade eder. Kesinlik, bir modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu ölçer.

$$Kesinlik = \frac{a}{a + c} \quad (4)$$

F1 Skoru:

F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasını temsil etmektedir. Daha doğru sonuçlara ulaşabilmek için bu iki metriği birleştirerek modelin performansını değerlendirir. F1 skoru hem yanlış negatifleri minimize etme hem de yanlış pozitifleri minimize etme arasında bir denge sağlamaya çalışır.

$$F1 Skoru = \frac{2 * Duyarlılık * Kesinlik}{Duyarlılık + Kesinlik} \quad (5)$$

Gini İndeksi:

Gini indeksi, karar ağaçları sınıflandırma algoritmasında kullanılan bir ölçüdür. Gini indeksi bir düğümün saflığını ölçmek amacıyla bir metrik olarak kullanılmaktadır. Karar ağaçları, verileri bir dizi karar kuralıyla bölerek sınıflandırma işlemini gerçekleştirir. Her düğüm, bir özellik ve bu özellik üzerindeki bir eşik değeri kullanarak verileri iki alt kümeye ayrılmaktadır. Gini indeksi, bu alt kümelerin ne kadar homojen olduğunu ölçmektedir. Gini indeksi, 0 ile 1 arasında bir değer alır. 0, bir düğümün tamamen homojen olduğunu, yani sadece tek bir sınıfa ait örnekler içerdiğini gösterirken, 1 ise düğümün en karışık durumda olduğunu, yani homojen olmayıp farklı sınıflara ait örneklerin karışık bir şekilde dağıldığını göstermektedir.

$$Gini İndeksi = 1 - \sum_{i=1}^c P(i)^2 \quad (6)$$

3. UYGULAMA VE BULGULAR

Çalışmada kullanılan veriler Türkiye’de faaliyet gösteren büyük ölçekli bir seramik sağlık gereçleri üretim tesisinden temin edilmiştir. Toplamda bir tür ürüne ait olmak üzere 2229 satır verinin 11 farklı öznitelikte değerli üzerinden çalışılmıştır. Kalite sınıflandırması için çalıştırılan modellerde kullanılan bilgisayar 8. nesil Intel i5 işlemcili 8GB dahili hafızaya sahiptir. Modellerin uygulamasında Python 3.10 ve buna bağlı kütüphaneler kullanılmıştır.

Tablo 3. Model başarı karşılaştırması

Yöntem	Doğruluk	Duyarlılık	Kesinlik	F1 Skoru
Lojistik Regresyon	0.77	0.95	0.75	0.84
Destek Vektör Makinaları	0.76	0.92	0.75	0.83
Karar Ağaçları	0.87	0.86	0.91	0.89


Tablo 3’de üç farklı model için elde edilen metrikler görünmektedir. Doğruluk metriği göz önüne alındığında karar ağaçlarıyla kurulan modelin 0.87 değeriyle diğer modellere karşı üstünlük kurduğu görünmektedir. Lojistik regresyon ve destek vektör makineleri (linear kernel) ile elde edilen sonuçların özellikle duyarlılık metriğinde karar ağaçlarına göre iyi olduğu gözlemlenmektedir. Duyarlılık dışındaki tüm ölçütlerde karar ağaçları modelinin başarısı gözlemlenmektedir. Bu durumu daha detaylı incelemek üzere karar ağaçları modelinden elde edilen diğer temel bilgiler Tablo 4’de verilmiştir. Buna göre modelin Gini İndeksi 0.86 şeklinde hesaplanmıştır. Bunun yanı sıra modelin eğitim seti ve test setindeki başarısının tutarlı olduğu gözlenmekte, buna bağlı olarak bir aşırı öğrenme durumunun olmadığı anlaşılmaktadır.

Tablo 4. Kriter gini indeksi ile model doğruluk puanları

Kriter Gini İndeksi ile Model Doğruluk Puanı	0.8640
Eğitim Seti Doğruluk Puanı	0.8181
Eğitim Seti Puanı	0.8181
Test Seti Puanı	0.8460

Bunların yanı sıra Şekil 3’te özniteliklere ait korelasyon tablosu bulunmaktadır. Bu analiz sayesinde incelenen özellikler arasındaki ilişkiler görülmektedir. Bazı özniteliklerde yüksek ters korelasyon görülmesiyle birlikte bu özniteliklerin model

üzerindeki etkisi üzerinde durulmamıştır. Bunun temel sebebi problem verisinin büyük boyutlu bir seramik sağlık gereçleri üretim tesisinden temini ve mevcut sistemde bu verilere bağlı olarak kalite sınıflandırmasının gerçekleştirilmesidir.



Şekil 3. Korelasyon Matrisi

4. TARTIŞMA VE SONUÇ

Bu çalışmada makine öğrenmesi teknikleri kullanarak seramik sağlık gereçleri ürünlerinin kalite sınıflandırılması üzerinde durulmuştur. Çalışmanın amacı doğrultusunda makine öğrenmesi yöntemlerinden lojistik regresyon, destek vektör makinaları ve karar ağaçları yöntemleri kullanılarak sınıflandırma analizleri gerçekleştirilmiştir. Analiz sonuçları her bir yöntemin performansını değerlendirmek için doğruluk, duyarlılık, kesinlik ve F1 skoru metrikleri kullanılmıştır. Sonuçlar değerlendirme metriklerine dayalı olarak karşılaştırılmıştır.

Elde edilen sonuçlar lojistik regresyon ve destek vektör makinaları yöntemlerinin benzer performans elde ettiğini göstermektedir. Her iki yöntem de yüksek duyarlılık, doğruluk, kesinlik ve F1 skoru değerlerine sahip olduğu görülmüştür. Ancak karar ağaçları yöntemi bu iki yönteme kıyasla daha yüksek bir doğruluk puanına sahiptir ve yüksek bir kesinlik puanı elde etmiştir. Bu sonuçlar karar ağaçları yönteminin seramik sağlık gereçleri ürünlerinin kalite sınıflandırılmasının daha doğru bir şekilde yapıldığını ve daha etkili olduğunu göstermektedir.

Bu çalışma, seramik sağlık gereçleri ürünlerinin kalite sınıflandırılması için makine öğrenmesi tekniklerini kullanmanın etkili bir yöntem olduğunu açıkça göstermektedir. Çalışmada ele alınan problem verileri doğrultusunda ürünlerinin kalite sınıflandırmasını gerçekleştiren personeller bulunmaktadır. Önerilen makine öğrenmesi modelleri sayesinde bu sınıflandırmayı yapan personel nitelikli iş gücünü başka işlere ayırabilecek ve sınıflandırma otonom bir şekilde gerçekleştirilebilecektir. Önerilen modelin kurumsal kaynak planlaması sistemine entegre olması, diğer ürünler için de model geçerliliklerinin gösterilmesi ve ürün çeşitliliğiyle verinin büyümesiyle birlikte derin öğrenme yöntemlerinin kullanımı gelecek çalışmalar arasında gösterilebilmektedir.

Yazar Katkı Oranları

Çalışmanın Tasarlanması (Design of Study): SŞ(% 50), EÖ(% 50)

Veri Toplanması (Data Acquisition): SŞ(% 50), EÖ(% 50)

Veri Analizi (Data Analysis): SŞ(% 50), EÖ(% 50)

Makalenin Yazımı (Writing Up): SŞ(% 50), EÖ(% 50)

Makale Gönderimi ve Revizyonu (Submission and Revision): SŞ(% 50), EÖ(% 50)

KAYNAKLAR

- Ramesh, P., & Mani, K. (2022). Prediction of surface roughness using machine learning approach for abrasive waterjet milling of alumina ceramic. *The International Journal of Advanced Manufacturing Technology*, 119(1-2), 503-516.
- Qu, N., Liu, Y., Liao, M., Lai, Z., Zhou, F., Cui, P., ... & Zhu, J. (2019). Ultra-high temperature ceramics melting temperature prediction via machine learning. *Ceramics International*, 45(15), 18551-18555.
- Ye, Y., Ni, Z., Hu, K., Li, Y., Peng, Y., & Chen, X. (2023). Dielectric constant prediction of perovskite microwave dielectric ceramics via machine learning. *Materials Today Communications*, 35, 105733.
- Chen, T., Wu, W., Li, W., & Liu, D. (2019). Laser cladding of nanoparticle TiC ceramic powder: Effects of process parameters on the quality characteristics of the coatings and its prediction model. *Optics & Laser Technology*, 116, 345-355.
- Çöpoğlu, M., Öztürk, G., Çimen, E., & Akdemir, S. C. (2023, May). Measuring Product Dimensions with Computer Vision in Ceramic Sanitary Ware Sector. In *International Symposium on Intelligent Manufacturing and Service Systems* (pp. 761-768). Singapore: Springer Nature Singapore.
- Cao, T., Song, K., Xu, L., Feng, H., Yan, Y., & Guo, J. (2024). Balanced multi-scale target score network for ceramic tile surface defect detection. *Measurement*, 224, 113914.
- Wan, G., Fang, H., Wang, D., Yan, J., & Xie, B. (2022). Ceramic tile surface defect detection based on deep learning. *Ceramics International*, 48(8), 11085-11093.
- Zhang, H., Peng, L., Yu, S., & Qu, W. (2021). Detection of surface defects in ceramic tiles with complex texture. *IEEE Access*, 9, 92788-92797.
- Lu, Q., Lin, J., Luo, L., Zhang, Y., & Zhu, W. (2022). A supervised approach for automated surface defect detection in ceramic tile quality control. *Advanced Engineering Informatics*, 53, 101692.
- European Commission. (2007). Reference document on best available techniques in the ceramic manufacturing industry. *Ceram. Manuf. Ind*, 210-211.
- Canduran, K., & Ural, M. (2019). Seramik Sağlık Gereçleri Üretiminde Deformasyonu Önlemek İçin Kullanılan Aparatlar. *Akademik Sanat*, (8).
- Kunduracı, N., Binal, G., & Şimşek, İ. N. G. (2017). Seramik Sağlık Gereçleri Fine Fire Clay Ürünlerinde Şamot Alternatif Malzemelerin Kullanımının Araştırılması ve Sentezlenmesi. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 17(1), 203-208.

- Bernasconi, A., Pellegrino, L., Vergani, F., Campanale, F., Marian, N. M., Galimberti, L., ... & Capitani, G. (2023). Recycling detoxified cement asbestos slates in the production of ceramic sanitary wares. *Ceramics International*, 49(2), 1836-1845.
- Epa, U. (1995). AP-42: Compilation of Air Emissions Factors. *Research Triangle Park NC: US Environmental Protection Agency*.
- Cultrone, G., & Madkour, F. (2013). Evaluation of the effectiveness of treatment products in improving the quality of ceramics used in new and historical buildings. *Journal of Cultural Heritage*, 14(4), 304-310.
- Coskun, H., Yiğit, T., & Üncü, İ. S. (2022). Integration of digital quality control for intelligent manufacturing of industrial ceramic tiles. *Ceramics International*, 48(23), 34210-34233.
- Zhao, Z. (2021). Review of non-destructive testing methods for defect detection of ceramics. *Ceramics International*, 47(4), 4389-4397.
- Cristianini N, Shawe-Taylor J. An introduction to support vector machines and other kernel-based learning methods. Cambridge: Cambridge University Press; 2000.
- Scholkopf B, Smola A. Learning with kernels: support vector machines, regularization, optimization, and beyond. Cambridge, MA: MIT Press; 2002.
- Breiman L et al. Classification and regression trees. Belmont, CA: Wadsworth; 1984.
- Quinlan R. C4.5: programs for machine learning. Los Altos, CA: Morgan Kaufmann; 1993.
- LaValley, M. P. (2008). Logistic regression. *Circulation*, 117(18), 2395-2399.