





## Adli bilim ve adli tıpta makine öğrenmesi: Literatür üzerine araştırma Machine learning in forensic science and forensic medicine: Research on the literature

 Sultan Turhan<sup>1</sup>,  Mert Tunç<sup>2</sup>,  Eralp Doğu<sup>1</sup>,  Yasemin Balcı<sup>2</sup>  
0000-0002-9704-1700 0000-0002-5347-212X 0000-0002-8256-7304 0000-0002-5995-9924

<sup>1</sup>Department of Statistics, School of Medicine, Muğla Sıtkı Koçman University, Muğla, Türkiye

<sup>2</sup>Department of Forensic Medicine, School of Medicine, Muğla Sıtkı Koçman University, Muğla, Türkiye

**Corresponding author:** Sultan Turhan

Department of Statistics, Muğla Sıtkı Koçman University, Muğla, Türkiye

email: sultantrhn@hotmail.com

Cite as: Turan S, Tunc M, Dogu E, Balcı Y. Machine learning in forensic science and forensic medicine : Research on the literature. J For Med 2022;36(1):1-7.

### ABSTRACT

Machine learning methods achieve very successful results in understanding and interpreting the large data sets that have emerged with digitalization today. Our aim in this study is to investigate machine learning methods in the fields of forensic science and forensic medicine and to analyze the trends in this field.

In the study, 404 articles were reached by using the search term "Forensic Machine Learning" between 1988-2021 in PubMed database and 220 articles were shared by using the search term "Forensic Medicine Machine Learning" between 1999-2021.

It was determined that machine learning methods were used most frequently in the estimation of gender and age in the fields of forensic science and forensic medicine. In addition, while it was determined that the most used machine learning method was "artificial neural networks", the most used method evaluation criterion was "accuracy".

As a result, we aim to encourage forensic science and forensic medicine experts to work on machine learning, which is a new approach in forensic science and forensic medicine.

**Keywords:** Forensic science, forensics, machine learning, Pubmed.

### ÖZET

Makine öğrenmesi yöntemleri, günümüzde dijitalleşme ile ortaya çıkan büyük veri setlerini anlamada ve yorumlamada oldukça başarılı sonuçlar elde etmektedir. Bu çalışmadaki amacımız, adli bilim ve adli tıp alanlarında makine öğrenmesi yöntemlerini araştırmak ve bu alandaki eğilimleri analiz etmektir.

Çalışmada PubMed veri tabanında 1988-2021 yılları arasında "Forensic Machine Learning" arama terimi kullanılarak 404 makale ve 1999-2021 yılları arasında "Forensic Medicine Machine Learning" arama terimi kullanılarak ortak olan 220 makaleye ulaşılmıştır.

Adli bilim ve adli tıp alanlarında makine öğrenme yöntemlerinin en sık cinsiyet ve yaş tahmininde kullanıldığı belirlenmiştir. Ayrıca en çok kullanılan makine öğrenmesi yönteminin "yapay sinir ağları" olduğu tespit edilirken en fazla kullanılan yöntem değerlendirme kriteri "doğruluk" olarak bulunmuştur.

Sonuç olarak; adli bilim ve adli tıpta yeni bir yaklaşım olan makine öğrenimine adli bilim ve adli tıp uzmanlarını makine öğrenimi çalışmalarına teşvik etmeyi amaçlıyoruz.

**Anahtar Kelimeler:** Adli bilim, adli tıp, makine öğrenmesi, Pubmed.

### GİRİŞ

Makine öğrenmesi (MÖ), bilgisayarların veri tabanlarındaki verileri yorumlanmasına dayalı, algoritmaların tasarım ve geliştirme süreçlerini inceleyen istatistik, matematik ve bilgisayar bilimlerini kullanan çok disiplinli bir alan olarak tanımlanır. MÖ büyük ve karmaşık görevlerin üstesinden gelmek için verilerden öğrenen ve zaman içinde doğruluğu arttıran modeller oluşturmaya odaklanır (1). Modern MÖ'nün üç amacı bulunur; ilk amaç geçmiş verileri kullanarak özniteliklerle (bağımsız değişkenler) yanıt değişkeni (bağımlı değişken) arasında yüksek performanslı modeller geliştirmek, ikinci amaç bu modelleri yeni ve etiketlenilmemiş verilerin sınıflandırılmasında kullanmak, yorum yapmak ve klinikte kullanılmasını sağlamaktır. Çok farklı alanlarda kullanım imkânına sahip bu teknolojilerin altında yatan temel mantık, verilerden desenler çıkarma ve bu desenlerden uygulamada yararlanılması için modeller geliştirilmesidir. Verilerin yararlı ve yeterli bir modele dönüştürülmesi ve modelin kullanılması yararlanılan alanda referans olarak kullanılması ile karar verme, aykırı durumları tespit etme, fark edilemeyen örüntüleri bulma ve ayırma yapabilme yetenekleri elde edilmiş olmaktadır (2).

MÖ diğer bilimlerde olduğu gibi tıp alanında da kendine yer bulmuştur. Son 10 yılda kardiyoloji (3), ortopedi (4), psikoloji (5), tıbbi genetik (6) ve adli bilimler alanları da dâhil olmak üzere pek çok alandaki araştırmalarda MÖ yöntemlerinin kullanıldığı görülmüştür. MÖ teknikleri, hastalık tahmininden prognoz belirlemeye kadar tıbbi uygulamalarda artan bir ilgi


görmüştür (7). Adli bilimlerde, hekimin tecrübesi ve yorumu ön plana çıkmaktadır. Bazı konularda hekimler arası farklı yorumların olması makine öğreniminin önemini gündeme getirmiştir. Son yıllarda, postmortem interval belirleme (8), silah paterni ve atış mesafesinin saptanması (9), yaş (10) ve cinsiyet (11) tayini ve kimliklendirme (12) gibi adli bilimlerin konusu olan çalışmalarda MÖ kullanımı artmıştır.

Çalışmanın amacı, adli tıp ve/veya adli bilimlerle ilgili MÖ içeren çalışmaların incelenerek, konu ile ilgili MÖ güncel yaklaşımlarını görmek, alanda hangi sorunların çözümüne katkısı olabileceğini araştırmaktır.

### Araştırma Kapsamı

Çalışmada PubMed veri tabanından yararlanılmış olup akış diyagramı Şekil 1.'de verilmiştir.

Literatür taramasında anahtar kelimeler "Forensic Machine Learning" ve "Forensic Medicine Machine Learning" şeklindedir. Bu literatür taraması sonucunda yıllara göre çalışma sayısı, en sık kullanılan yöntemler ve kriterler belirlenmiştir. PubMed'de 1988-2021 yılları arasında "Forensic Machine Learning" anahtar kelimeleri ile 404 çalışmaya ulaşılmışken 1999-2021 yılları arasında "Forensic Medicine Machine Learning" anahtar kelimeleri ile 220 çalışmaya ulaşılmıştır. 404 makaleden 259 tanesi, 220 çalışmadan 75 tanesi içerik ve dil açısından çalışmanın dışında tutularak incelemeye 145 çalışma ile devam edilmiştir.

**Şekil 1.** Literatür Taraması Akış Diyagramı

Bu literatür taramasında geçen MÖ yöntemleri, regresyon, artırma, kümeleme, bayes, dalgalanma azaltma kuralı öğrenen sınıflandırıcı (RIDOR), tekrarlanan artımlı budama (JRIP), genetik algoritma (GA), diskriminant analizi (DA), karar ağacı (KA), Naive Bayes (NB), rasgele orman (RO), destek vektör makineleri (SVM), yapay sinir ağı (YSA), bulanık c-ortalama kümeleme (BCOK), k-en yakın komşu (KNN), lojistik regresyon (LR), KSTAR, torbalama, J48, kolektif öğrenme (KÖ) şeklindedir. Değerlendirme kriterleri ise, karışıklık matrisi (KM), doğruluk, duyarlılık, özgüllük, kesinlik, eğri altındaki alan (AUC), F1, kappa, Matthews Korelasyon Katsayısı (MKK), bilgi kriteri (BK), R-kare, geometrik ortalama, sağlamlık şeklindedir.

Çalışma açık kaynak kodlu R programı ile gerçekleştirilmiş ve grafikler ggplot2 paketi ile oluşturulmuştur. Veri setine [https://github.com/sultan-turhan/adlibilimler\\_adlit-p](https://github.com/sultan-turhan/adlibilimler_adlit-p) Github adresinden erişilebilir.

### Makine Öğrenmesi ve Değerlendirme Kriterleri

Makine öğrenmesi büyük ve karmaşık verilerden öğrenen ve zaman içinde doğruluğu artıran modeller oluşturmaya odaklanan istatistik, matematik ve bilgisayar bilimlerinden yararlanan bir alandır (1,2). MÖ yöntemleri genel olarak 3'e ayrılır. Bunlar denetimsiz öğrenme, denetimli öğrenme ve pekiştirmeli öğrenme yöntemleridir. Denetimsiz öğrenme (Unsupervised Learning), eğitim verilerine karşılık gelen etiketleri (yanıt değişken değerleri) olmayan giriş verilerinden oluşur. Denetimsiz öğrenme yönteminin temel amacı öznitelikler arasındaki ilişkiyi ve verinin gizli yapısından keşfetmeye çalışmaktır. Denetimli öğrenme (Supervised Learning), yanıt değişkeninin değerini, öznitelikler grubundan tahmin etmek olarak tanımlanır. Pekiştirmeli öğrenme (Reinforcement Learning) istenen davranışları ödüllendirmeye, istenmeyen davranışları cezalandırmaya dayalı yöntemdir (13-15). Bu yöntemler genel olarak 4 başlık altında incelenir. Bunlar; ağaç temelli yöntemler, olasılığa dayalı yöntemler, destek vektör makineleri ve yapay sinir ağlarıdır. Ağaç temelli yöntemler, tahmine dayalı modelleri yüksek doğruluk ve yorumlama kolaylığı ile destekler. Doğrusal modellerin aksine, doğrusal olmayan ilişkileri oldukça iyi tahmin eder. Ağaç tabanlı yöntemler, tahmin alanını basit bölgelere ayırır. Tahmin uzayını bölümlere ayırmak için kullanılan bölme kuralları kümesi bir ağaçta özetlenebildiğinden, bu tür yaklaşımlar karar ağacı yöntemleri olarak bilinir. Karar ağaçları, rastgele orman, gradyan artırma gibi yöntemler, her türlü veri bilimi probleminde yaygın olarak kullanılmaktadır (16, 17). Olasılığa dayalı yöntemler, yalnızca bir gözlemin göz önüne alındığında, sadece gözlemin ait olması gereken en olası sınıfı çıkarmaktan ziyade, bir sınıflar kümesi üzerindeki olasılık dağılımını tahmin edebilen bir sınıflandırıcıdır. Olasılıklığa dayalı yöntemlerin önemli yanı, tahminlerle bağlantılı belirsizlik hakkında bir fikir vermeleridir (18). Destek vektör

makineleri (SVM)'nin temelleri 1960'lara kadar dayandırılrsa da 1995 yılında yayınlanmıştır (19). Bu algoritmada, her bir veri ögesi, her özelliğin değeri belirli bir koordinatın değeri olacak şekilde n-boyutlu uzayda (n özelliklerin sayısı) bir nokta olarak çizilir. Daha sonra, iki sınıfı oldukça iyi ayıran hiperdüzlem bulunarak sınıflandırma yapılır (20). Yapay sinir ağları (YSA), insan beyninin bilgi işleme mantığından esinlenerek, basit biyolojik sinir sisteminin çalışma şekli taklit ederek geliştirilmiş bir teknolojidir. Yani biyolojik nöron hücrelerinin ve bu hücrelerin birbirleri ile arasında kurduğu bağın dijital olarak modellenmesidir (21). YSA'lar bilgiyi verilerdeki kalıpları ve ilişkileri tespit ederek deneyim yoluyla öğrenir (22).

Bu yöntemlerin doğru bir şekilde değerlendirilmesi oldukça önemlidir ve genel olarak kullanılan standart değerlendirme ölçütleri karışıklık matrisine (confusion matrix) dayanmaktadır (23).

Karışıklık matrisi tahminlerin doğruluğu hakkında bilgi veren 2x2'lik bir matristir (Tablo 1).

**Tablo 1.** Karışıklık matrisi

		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Matris, gerçek hedef değerleri MÖ modeli tarafından tahmin edilen değerlerle karşılaştırır. Doğruluk (accuracy) diğer kullanılan bir değerlendirme ölçütüdür (23). Doğruluk kriteri modelde doğru tahmin edilen cevapların (DP+DN), tüm cevaplara (DP+YP+YN+DN) oranı olarak açıklanabilir (14). Doğruluk,

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + YN + DN}$$

Kappa, iki değerleyici arasındaki uyumun güvenilirliğini ölçen bir istatistik yöntemidir (23). Kappa, (P<sub>0</sub> kabul edilen oran, P<sub>c</sub> kabul edilmesi beklenen oran)

$$K = \frac{P_o - P_c}{1 - P_c}$$

Duyarlılık (sensitivity), tahmin edilen pozitif sınıf değerlerinin (DP), tüm pozitif sınıf değerlerine (DP+YN) oranıdır (24). Duyarlılık,

$$\text{Duyarlılık} = \frac{DP}{DP + YN}$$

Özgüllük (specificity), doğru tahmin edilen negatif sınıf değerlerinin (DN), tüm negatif sınıf değerlerine oranıdır (24). Özgüllük,

$$\text{Özgüllük} = \frac{DN}{DN + YP}$$

Kesinlik (precision), doğru tahmin edilen pozitif sınıf değerinin (DP), bütün pozitif olarak tahmin edilen sınıf değerlerine (DP + YP) oranıdır (24). Kesinlik,

$$\text{Kesinlik} = \frac{DP}{(DP + YP)}$$

F-Ölçütü (F-Measure), kesinlik ve duyarlılık ölçütlerini beraber değerlendirmek daha doğru sonuçlar verir. Bu yüzden F-ölçütü tanımlanmıştır. F-ölçütü, kesinlik ve duyarlılığın harmonik ortalamasıdır (24). F-ölçütü,

$$F = 2 * \frac{(DP * \text{Kesinlik})}{(DP + \text{Kesinlik})}$$

Alıcı çalışma özellikleri (receiver operating characteristics-ROC): ROC duyarlılık ve özgüllük değerleri arasındaki ilişkiyi grafiksel olarak gösterir. ROC eğrisi doğru pozitif orana (duyarlılık) karşın yanlış pozitif oranını (1-özgüllük) noktalanarak çizilmesiyle elde edilir. Grafikte eğri altında kalan alan (AUC) değeri 1'e yaklaştıkça tanı değeri yükselmektedir (25).

Mathews Korelasyon Katsayısı (Mathews Correlation Coefficient-MKK): MKK, gerçek sınıf ve tahmin edilen ikili sınıflandırmalar arasında bir korelasyon katsayısıdır (25). MKK,

$$\text{MKK} = \frac{DP * DN - YP * YN}{\sqrt{(DP + YP)(DP + YN)(DN + YP)(DN + YN)}}$$

Geometrik ortalama,  $X_1, X_2, \dots, X_n$  pozitif sayıların geometrik ortalaması, sayıların çarpımlarının n. dereceden köküdür (26). Geometrik ortalama,

$$GO = \sqrt[n]{X_1 * X_2 * \dots * X_n}$$

Belirlilik katsayısı ( $R^2$ ), regresyon modelinin uyum yeterliliğinin değerlendirilmesinde kullanılan kriterlerden birisidir. Belirlilik katsayısı  $X_1, X_2, \dots, X_n$  bağımsız değişkenler tarafından açıklanabilen Y bağımlı değişkenindeki toplam değişkenliğin oranı olarak tanımlanır (27). Belirlilik katsayısı,

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST}$$


Bilgi kriteri, belirli bir veri kümesi için kaliteli bir istatistiksel göreceli model ölçüsüdür. Belirli bir modelin kullanılması durumunda kaybedilecek bilginin bir tahminini sağlar (28). Bu değerlendirme kriterleri MÖ yöntemlerinin karşılaştırılmasında büyük kolaylık sağlamaktadır.

### Yıllar Bazında Adli Tıpta Makine Öğrenmesi Üzerine Yayınlanmış Makale Sayıları ve Kullanım Yerleri

Adli bilimler ve adli tıpta makine öğrenmesi yöntemi ile yapılan 145 çalışma yıllar bazında Şekil 2.'de verilmiştir.


Bu çalışmalar yıllar bazında incelendiğinde, çalışmaların artan bir trend yakaladığı ve bu alandaki en fazla çalışmanın 2020 yılında gerçekleştirildiği görülmektedir. Bu çalışmalar kimliklendirme, yaş tayini, suç potansiyeli tespiti, travma ve ölüm nedeni tespiti, postmortem interval, ateşli silah çeşit tespiti, olay yeri kanıt tespiti ve olayla ilişkilendirme, künt-penetrant travma mekanizması tespiti, cinsel saldırı ve kanıt tespiti, uyuşturucu ve ilaç tespiti şeklinde alt gruplara ayrılmıştır. Alt gruplardaki çalışma sayıları Şekil 3.'de verilmiştir.

Şekil 2. Yıllar Bazında Çalışma Sayısı



Bu gruplar incelendiğinde kimliklendirmede 71, yaş tayininde 28, suç potansiyeli tespitinde 13, travma ve ölüm nedeni tespitinde 9, postmortem intervalde 6, ateşli silah çeşit tespitinde 5, olay yeri kanıt tespiti ve olayla ilişkilendirmede 5, künt-penetrant travma mekanizması tespitinde 3, cinsel saldırı ve kanıt tespitinde 3, uyuşturucu ve ilaç tespitinde 2 çalışma yer aldığı tespit edilmiştir.

Şekil 3. Alt Grup Çalışma Sayıları



### Adli Tıpta Makine Öğrenmesi Üzerine Yayınlanmış Makalelerde Kullanılan Yöntemler

Bu gruplardaki çalışmaların yararlandığı MÖ yöntemleri çıkarılmış ve bu yöntemler Şekil 4.-6.'da verilmiştir. Alt gruplar, kullanılan MÖ yöntemleri açısından sınıflandırılmıştır. Bu grafiklerde yatay eksen, kullanılan yöntem gruplarını ifade ederken dikey eksen, çalışma sayısını vermektedir. Gruplar için yararlanılan yöntemler Şekil 4.'te verilmiştir.


Kimliklendirmede en sık kullanılan yöntem YSA, yaş tayininde en sık kullanılan yöntem regresyon, suç potansiyel tespitinde en sık kullanılan yöntem regresyon, travma ve ölüm nedeni tespitinde en sık kullanılan yöntem YSA yöntemidir. Diğer gruplar için yararlanılan yöntemler Şekil 5.'te verilmiştir.

Künt penetrant travma mekanizma tespitinde en sık kullanılan yöntemler KA ve DA, olay yeri kanıt tespiti ve olayla ilişkilendirmede YSA, cinsel saldırı varlığı ve kanıt tespitinde en sık kullanılan yöntem regresyon, ateşli silah çeşidi tespitinde en sık kullanılan yöntem regresyon yöntemidir. Diğer gruplar için yararlanılan yöntemler Şekil 6'te verilmiştir.

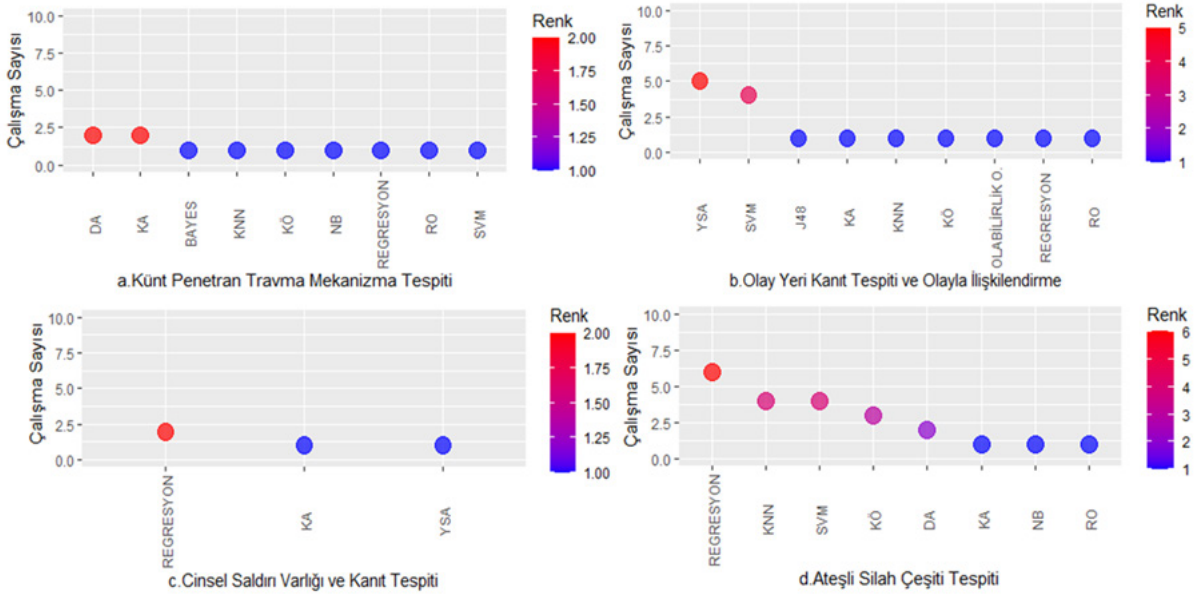
Uyuşturucu ve ilaç tespitinde en sık kullanılan yöntemler artırma ve SVM olurken postmortem interval de regresyon kullanılmıştır.

Sonuç olarak alt gruplar değerlendirildiğinde en sık kullanılan yöntem olarak YSA olduğu tespit edilmiştir.


Şekil 4. Gruplar Bazında Yararlanılan MÖ Yöntemleri



Şekil 5. Gruplar Bazında Yararlanılan MÖ Yöntemleri



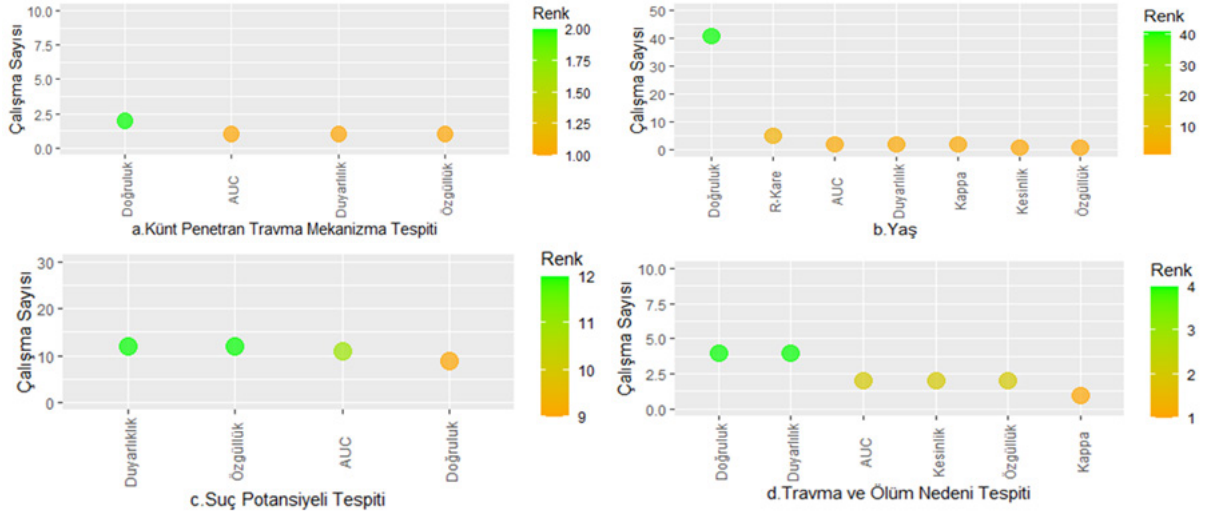
Şekil 6. Gruplar Bazında Yararlanılan MÖ Yöntemleri



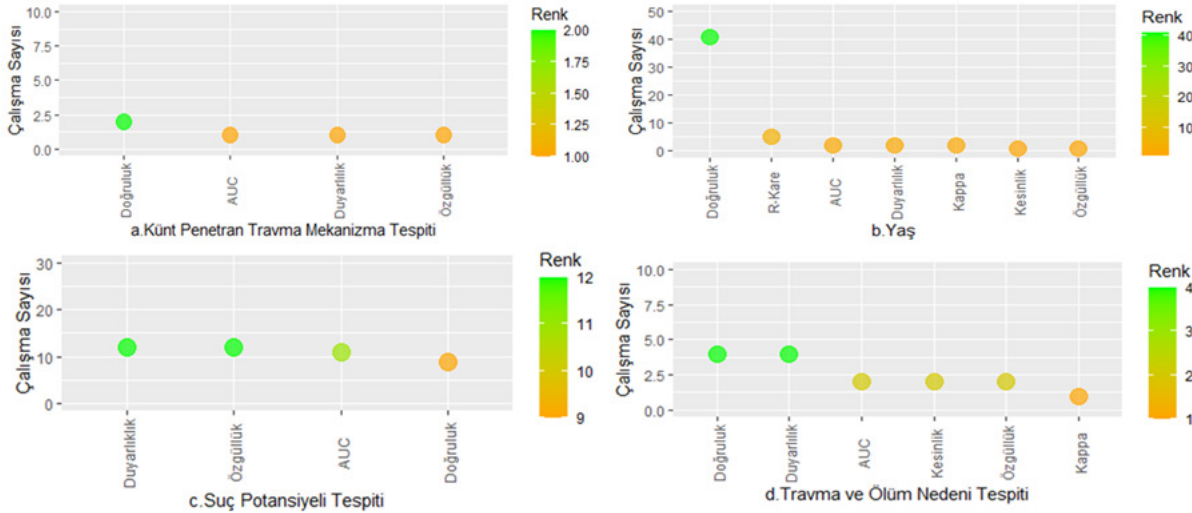
### Adli Tıpta Makine Öğrenmesi Üzerine Yayınlanmış Makalelerde Kullanılan Performans Kriterleri

Adli tıpta makine öğrenmesi üzerine yayınlanmış makalelerde kullanılan performans kriterleri Şekil 7.-9.'de verilmiştir. Bu grafiklerde yatay eksen kullanılan değerlendirme kriterini ifade ederken dikey eksen çalışma sayısını ifade etmektedir. Gruplar için yararlanılan kriterler Şekil 7.'de verilmiştir. Bu noktada kimliklendirme alt grubu için en sık kullanılan değerlendirme kriteri doğruluk, yaş tayini için en sık kullanılan kriter hata oranı, suç potansiyeli tespiti için duyarlılık ve travma ve ölüm nedeni tespiti için doğruluk bulunmuştur. Diğer gruplar için yararlanılan kriterler Şekil 8.'da verilmiştir. Künt penetran travma mekanizma tespiti için en sık kullanılan yöntem doğruluk, olay yeri kanıt tespiti ve olayla ilişkilendirmede doğruluk, cinsel saldırı varlığı ve kanıt tespitinde AUC ve ateşli silah çesidi tespitinde doğruluk kriterleri kullanılmıştır. Diğer gruplar için yararlanılan kriterler Şekil 9.'da verilmiştir.

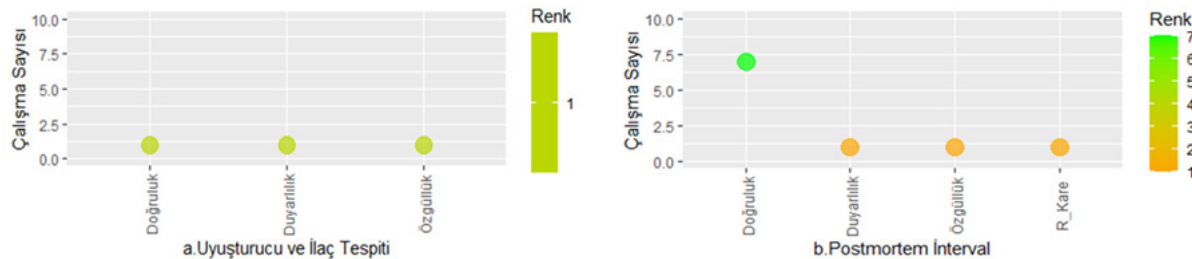
Şekil 7. Gruplar Bazında Yararlanılan MÖ Kriterleri



Şekil 8. Gruplar Bazında Yararlanılan Kriterler



Şekil 9. Gruplar Bazında Yararlanılan Kriterler



## TARTIŞMA VE SONUÇ

Pubmed veri tabanından yararlanılarak “Forensic Machine Learning” ve “Forensic Medicine Machine Learning” anahtar kelimeleri ile yapılan literatür taramasında ortak 145 çalışma incelenmiş olup son yıllarda bu alanda yapılan çalışmalarda önemli bir artış saptanmış, en çok kullanılan alt alan kimliklendirme, en çok kullanılan yöntem olarak YSA bulunmuştur. En çok kullanılan kriter doğruluk olarak bulunmuştur.

Çalışma genel olarak incelendiğinde en sık kullanılan yöntemlerin daha anlaşılır ve kolay uygulanabilir yöntemler olduğu tespit edilmiştir. Özellikle geleneksel yöntemler veri setinde gürültü, kayıp gözlem ve sınıf dengesizliği problem gibi problemler ile karşılaştığında yanlış ve düşük sınıflandırma başarısı elde etmektedir. Bu tarz problemlerde geleneksel yöntemlerden daha başarılı sonuçlar elde edebilen (29, 30,31), verilerdeki karmaşık, doğrusal olmayan ilişkileri yakalama konusunda çok daha yüksek bir güce sahip olan kolektif öğrenme yöntemlerine geçiş yapılması önerilmektedir. Ayrıca gürültü, kayıp gözlem ve sınıf dengesizliği problemi gibi durumlar ile karşılaşıldığında MÖ yöntemlerinin değerlendirilmesinde doğruluk kriterinin tek başına modeli ifade etmede yeterli kabul edilmemesi (32) nedeni ile diğer değerlendirme kriterlerinin de incelenmesini önermekteyiz.

Tüm bu çalışmalar ışığında MÖ yöntemlerinin adli bilimler ve adli tıp alanında kullanımının çok yeni olduğu ve günümüzde büyük bir ilginin olduğunu ortaya konmuştur. Bu çalışma kapsamında adli bilimler ve adli tıp alanında çalışan uzmanların MÖ yöntemlerinden yararlanarak daha hızlı etkin sonuçlar elde edebileceklerini öngörüyor ve MÖ yöntemlerinin çalışmalarda kullanılmasını öneriyoruz.

## KAYNAKLAR

1. Mitchell TM, Machine Learning. 1st. New York: McGraw-Hill, 1997:p.414.
2. Michie D, Spiegelhalter D, Taylor C. Machine Learning, Neural and Statistical Classification. Technometrics 1999;37.
3. Miller DD. Machine Intelligence in Cardiovascular Medicine. *CardiolRev* 2020 ;28(2):53-64.
4. Cabitza F, Locoro A, Banfi G. Machine Learning in Orthopedics: A Literature Review. *Front Bioeng Biotechnol* 2018;27(6):75.
5. Erbay LG, Celbiş O, Oruç M, Karlıdağ R. Investigation using psychological autopsy method of completed suicide cases coming to the Council of Forensic Medicine, Malatya Regional Office. *Journal Of Forensic Medicine* 2020;34(1):1-6.
6. Libbrecht MW, Noble WS. Machine learning applications in genetics and genomics. *NatRevGenet* 2015;16(6):321-32.
7. Guan X, Zhang B, Fu M, Li M, Yuan X, Zhu Y, Peng J, Guo H, Lu Y. Clinical and inflammatory features based machine learning model for fatal risk prediction of hospitalized COVID-19 patients: results from a retrospective cohort study. *AnnMed* 2021;53(1):257-66.
8. Liu R, Gu Y, Shen M, Li H, Zhang K, Wang Q, Wei X, Zhang H, Wu D, Yu K, Cai W, Wang G, Zhang S, Sun Q, Huang P, Wang Z. Predicting post-mortem interval based on microbial community sequences and machine learning algorithms. *Environ Microbiol* 2020;22(6):2273-91.
9. Gallidabino MD, Barron LP, Weyermann C, Romolo FS. Quantitative profile-profile relationship (QPPR) modelling: a novel machine learning approach to predict and associate chemical characteristics of unspent ammunition from gunshot residue (GSR). *Analyst* 2019;119:144(4):1128-39.
10. Vidaki A, Montiel González D, Planterose Jiménez B, Kayser M. Male-specific age estimation based on Y-chromosomal DNA methylation. *Aging (Albany NY)* 2021;11;13(5):6442-58.
11. Ortega RF, Iruira J, Campo EJE, Mesejo P. Analysis of the performance of machine learning and deep learning methods for sex estimation of infant individuals from the analysis of 2D images of the ilium. *Int J Legal Med* 2021;135(6):2659-2666.
12. Navega D, Vicente R, Vieira DN, Ross AH, Cunha E. Sex estimation from the tarsal bones in a Portuguese sample: a machine learning approach. *Int J Legal Med.* 2015;129(3):651-9.
13. He H, ve Garcia EA, Learning from Imbalanced Data. *IEEE Transactions on Knowledge and Data Engineering* 2009;21:1263–84.
14. Ge Z, Song Z, Ding SX, Huang B. Data Mining and Analytics in the Process Industry: The Role of Machine Learning *IEEE Access* 2017;5:20590–616.
15. Kavakiotis I, Tsave O, Salifoglou A, Maglaveras N, Vlahavas I, Chouvarda I. Machine Learning and Data Mining Methods in Diabetes Research. *Computational and Structural Biotechnology Journal* 2017;15:104–16.
16. Kern C, Klausch T, Kreuter F. Tree-based machine learning methods for survey research. In *Survey research methods* 2019;13(1):73.
17. Cutler A, Cutler DR, Stevens JR. Tree-based methods. In *High-Dimensional Data Analysis in Cancer Research*. Springer, New York. 2008:p.1-19.

18. Ghahramani, Z. Probabilistic machine learning and artificial intelligence. *Nature* 2015; 521(7553):452-9.
19. Cortes C, Vapnik V, Support Vector Networks. *Mach Learn* 1995;20, 273–97.
20. Fung G, Sandilya S, Rao RB. Rule extraction from linear support vector machines. Conference: Proceedings of the Eleventh ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, August 2005;21-4. Chicago, Illinois, USA.
21. Kustrin SA, Beresford R, Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis* 2020; 22(5)717-27.
22. Zou J, Han Y, So SS. Overview of Artificial Neural Networks. In: Livingstone D.J. (eds) *Artificial Neural Networks. Methods in Molecular Biology™*. 2008;458:15-23. Humana Press.
23. Bilgin M. Performance Analysis of Classical Machine Learning Methods on Real Datasets [in Turkish]. *Breast* 2017;2(9);683.
24. Nizam H, Akın SS. Comparison of the Performance of Balanced and Unbalanced Datasets in Sentiment Analysis with Machine Learning in Social Media [in Turkish]. XIX. Internet Conference in Turkey, 2014:1-6.
25. Karlı ÖB. Diagnosis of Liver Disease with Machine Learning Methods [in Turkish]. Ağrı İbrahim Çeçen University. Master Thesis. Ağrı,2019.
26. Mikkonen HG, Clarke BO, Dasika R, Wallis CJ, Reichman SM, Evaluation of methods for managing censored results when calculating the geometric mean, *Chemosphere* 2018;191:412-16.
27. McIntyre S H, Montgomery DB, Srinivasan V, Weitz BA, Evaluating the statistical significance of models developed by stepwise regression. *Journal of Marketing Research* 1983;20(1):1–11.
28. Hocking RR, A Biometrics invited paper: The analysis and selection of variables in linear regression. *Biometrics* 1976;32(1):1–49.
29. Kruse C, Eiken P, Vestergaard P. Machine Learning Principles Can Improve Hip Fracture Prediction. *Calcif. Tissue Int* 2017;100(4):348-60.
30. Liu Z, Tang D, Cai Y, Wang R, Chen F, A hybrid method based on ensemble WELM for handling multi class imbalance in cancer microarray data. *Neurocomputing* 2017;266:641-50.
31. Turhan S, Özkan Y, Suner A, Doğu E. Comparison of Ensemble Learning Methods for Disease Diagnosis in Presence of Class Unbalanced: Case of Diabetes. *Turkiye Klinikleri J Biostat* 2020;12(1):16-26
32. Gu H, Song T. Balanced Sampling Method for Imbalanced Big Data Using AdaBoost. In *Proceedings of the International Joint Conference on Bio-medical Engineering Systems and Technologies* 2015;189-94.