

Atf İçin: Gündoğdu S, 2021. Osteoporozla Bağlı Kifozlu Hastalara Uygulanan Egzersizlerin Oluşturduğu Denge Değişikliklerine İlişkin Veriler Kullanılarak Yapay Sinir Ağlarının Diğer Sınıflandırma Algoritmalarıyla Karşılaştırılması. İğdir Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 11(4): 2660-2672.

To Cite: Gündoğdu S, 2021. Comparison of artificial neural networks with other classification algorithms using data on balance changes caused by exercises applied to patients with kyphosis due to osteoporosis. Journal of the Institute of Science and Technology, 11(4): 2660-2672.

Osteoporozla Bağlı Kifozlu Hastalara Uygulanan Egzersizlerin Oluşturduğu Denge Değişikliklerine İlişkin Veriler Kullanılarak Yapay Sinir Ağlarının Diğer Sınıflandırma Algoritmalarıyla Karşılaştırılması

Serdar GÜNDOĞDU^{1*}

ÖZET: Osteoporoz, sırt kas gücünde azalma, ağrı, şekil bozuklukları, esneklik kaybı, vertebral veya non-vertebral kırık oluşturması gibi nedenlerden dolayı hastaların yaşam kalitesini olumsuz etkileyen bir hastalıktır. Osteoporozla bağlı kifoz olan hastalarda egzersizlerin denge üzerine olumlu etkisi vardır. Bu çalışmada egzersiz etkisinin araştırılması için yapılan bir çalışmadaki veriler kullanılmıştır. Hastalara uygulanan egzersizlerin öncesi (EÖ) ve sonrası (ES) iki farklı durumu karakterize edebilecek en uygun sınıflandırıcıyı bulmak amaçlanmıştır. Sınıflandırıcılar için ihtiyaç duyulan öznitelikler, statik denge performans değerlendirme skorları (öznitelik I) ve fonksiyonel mobilite değerlendirme skorları (öznitelik II) olmuştur. 26 sınıflandırıcı performansı karşılaştırıldığında, %91.4'lik en yüksek başarı oranı öznitelik I ve öznitelik II'nin giriş olarak kullanıldığı yapay sinir ağı; %36.4'lük en düşük başarı oranı ile sadece öznitelik I nin giriş yapıldığı Kuadratik (Quadratic) destek vektör makinası (DVM) ve sadece öznitelik II'nin giriş yapıldığı Kübik (Cubic) DVM algoritmaları ile elde edilmiştir. Doğruluk oranı açısından en başarılı olan yapay sinir ağı yönteminin eğitim için harcadığı zaman diğer başarılı algoritmalara göre daha fazla olmuştur.

Anahtar Kelimeler: Denge, egzersiz, makine öğrenme, yapay sinir ağı.

Comparison of artificial neural networks with other classification algorithms using data on balance changes caused by exercises applied to patients with kyphosis due to osteoporosis

ABSTRACT: Osteoporosis is a disease that negatively affects the quality of life of patients due to reasons such as decreased back muscle strength, pain, deformities, loss of flexibility, and vertebral or non-vertebral fractures. Exercises have a positive effect on balance in patients with osteoporotic kyphosis. In this study, data from a study conducted to investigate the effect of exercise were used. It is aimed to find the most appropriate classifier that can characterize two different situations before and after exercises applied to patients. The attributes needed for the classifiers were static balance performance evaluation scores (attribute I) and functional mobility evaluation scores (attribute II). When the classifier performances are compared, the highest success rate of 91.4% is artificial neural networks where attribute I and attribute II are used as inputs; with the lowest success rate of 36.4%, it was obtained with Quadratic SVM where only attribute I was logged in and Cubic SVM algorithms where only attribute II was logged in. Artificial neural network method was more time spent on education than other successful algorithms.

Keywords: Balance, exercise, machine learning, artificial neural network

¹Serdar GÜNDOĞDU ([Orcid ID: 0000-0003-2549-5284](https://orcid.org/0000-0003-2549-5284)), Dokuz Eylül Üniversitesi, Bergama Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, İzmir, Türkiye

*Sorumlu Yazar/Corresponding Author: Serdar GÜNDOĞDU, e-mail: serdar.gundogdu@deu.edu.tr

GİRİŞ

Osteoporoz, kemik kırılabilirliğinin ve kırık olasılığının artışı, düşük kemik kütlesi, kemik mikro yapısının bozulması ile karakterize sistemik bir iskelet hastalığıdır (Alkan ve ark., 2011; Gündoğdu ve ark., 2013). Osteoporoz genellikle 45 yaşından sonra başlar ve yaş ilerledikçe görülme sıklığı artar. Çalışmalarda bölgesel farklılıklar gözlenmekte olup 50-60 yaş arası kadınlarda görülme sıklığı %40-55, 60- 70 yaş arası %75, 70 yaş üzeri ise %85-90 olarak bildirilmektedir (Walker-Bone ve ark., 2001). Osteoporoz, sırt kas gücünde azalma, ağrı, şekil bozuklukları, esneklik kaybı, vertebral veya non-vertebral kırık oluşturması gibi nedenlerden dolayı hastaların yaşam kalitesini olumsuz etkilemektedir (Sindel, 2002; Yılmaz ve ark., 2012). Osteoporozun yaşam kalitesine etkisi ilgi ilgili klinik çalışmalar son yıllarda yoğunlaşmıştır. Yapılan bir çalışmada osteoporoz ile ilişkili kifozu olan hastalar sağlıklı kişilerle karşılaştırıldığında denge sorunlarının daha fazla olduğu ve kas güçlerinin daha zayıf olduğu saptanmıştır (Sinaki ve ark., 2005). Denge kontrolü, duyuşal girdilerin bütünleşmesi yanında esnek hareket şekillerinin planlanması ve uygulanmasını içeren karmaşık bir motor yetenektir (Erkmen ve ark., 2007).

Osteoporoz teşhisi konulmuş hastaların rehabilitasyonunda etkili olan egzersiz temel unsurdur ve uygulanacak programın hastanın durumuna göre düzenlenmesi gerekmektedir (Bonner ve ark., 2005). Doruk kemik kütlesini maksimuma çıkarmak osteoporozun önlenmesinde ana amaçtır. Egzersiz yapmak, kemik mineral yoğunluğunun oluşmasında belirleyici faktörlerden biridir. Fiziksel olarak aktif kişilerin sedanter yaşam sürenlere göre daha yüksek kemik kütlesine sahip oldukları gözlemlenmiş olup egzersiz faaliyetlerin osteoporozda koruyucu rol oynadıkları anlaşılmıştır (Tosun ve Bölükbaşı, 2004). Osteoporoz için kuvvetlendirme egzersizleri germe egzersizleri, yüksek güçlü egzersizler, vücut ağırlığı ile yapılan egzersizler ve denge egzersizleri olmak üzere beş ayrı tipte program önerilmektedir (Eskiyurt, 2005).

Makine öğrenmesinin temel uygulama alanlarından biri olan sınıflandırma, bilinmeyen bir veri grubunu bilinen bir gruba yerleştirmekte kullanılmaktadır (Harrington, 2012). Makine öğrenmesi ile çok farklı alanlarda elde edilen veriler gruplandırılarak, sınıflandırılarak veya veriler arasındaki ilişkiler ortaya çıkarılarak yeni modeller oluşturulup geleceğe yön verilmeye çalışılmaktadır. Sınıflandırma, hayatımızın her alanında var olan çeşitli veri türlerini sınıflandırmak için kullanılan önemli bir veri madenciliği tekniğidir.

Onan'ın (2015) yaptığı çalışmada, 240 farklı şirketin finansal özellikleri içeren bir veri seti kullanarak şirket iflaslarının tahmin edilmesini ele almıştır. Elindeki verilere, tahmin etmede ve sınıflandırmada kullanılan yöntemlerden olan karar ağacına ilişkin 7 farklı algoritma uygulamıştır. Değerlendirmesine göre karar ağacının şirket iflaslarının tahmin etmede uygun bir yöntem olduğunu gözlemiştir (Onan, 2015). Tsangaratos ve Ilia (2016), heyelan duyarlılık değerlendirmelerinde Lojistik Regresyonu ve Naive Bayes algoritma sınıflandırıcıların performanslarını karşılaştırdılar. İki sınıflandırıcının karşılaştırmasını, ciddi heyelan olaylarıyla karşılaşılan Yunanistan'ın Epirus dağlarında bulunan 116 alan içeren bir veritabanının değerlendirilmesine dayandırdılar. Siteler heyelan olan ve heyelan olmayan alanlar olmak üzere iki kategoride sınıflandırdılar. Naive Bayes sınıflandırıcı için sonuçlar Lojistik Regresyon ile karşılaştırıldığında %87.50 doğrulukla Naive Bayes sınıflandırıcı, %82.61 hassasiyetle Lojistik Regresyon sınıflandırıcısı geride bırakmıştır (Tsangaratos ve Ilia, 2016). Pabuçcu (2019), 2009-2018 yılları aralığını kapsayan günlük kapanış fiyatlarını içeren BIST 100 veri seti kullanarak borsa endeksinin pozitif ve negatif yönlü hareketlerinin tahmin edilmesini araştırmıştır. Araştırmada destek vektör makinesi, Naive Bayes ve yapay sinir ağı algoritması olmak üzere üç makine öğrenme algoritması kullanılmış ve tahmin performansları karşılaştırılmıştır. En iyi sınıflandırıcı

algoritmasının destek vektör makineleri olduğu sonucuna ulaşmıştır (Pabuççu, 2019). Altuntaş ve Kocamaz (2019), haploid ve diploid mısır tohumlarını sınıflandırmak için renk momenti özneliklerine dayalı bir bilgisayar destekli yöntem önermiş ve RGB, HSV ve Lab 3 farklı renk uzayı karşılaştırmalı olarak test edilmiştir. 3000 mısır tohumundan oluşan veri seti üzerinde yürüttükleri çalışmada, elde ettikleri öznelikler destek vektör makinesi ile sınıflandırılmıştır. Sonuçlara göre en iyi performansı Lab renk uzayında %87.03 doğruluk, %80.15 duyarlılık ve %93.00 özgünlük değerleriyle elde etmişlerdir (Altuntaş ve Kocamaz, 2019).

Küçük ve ark. (2019), nöromusküler hastalıklardan olan ALS ve Myopati hastalıklarının teşhisi için bir sınıflandırma yapısı düzenlenmişlerdir. Bu çalışmada Destek Vektör Makinesi, K-En Yakın Komşu algoritması ve Diskiriminant Analiz algoritmaları ile verileri sınıflandırmışlardır. Doğrulama ölçütü olarak çapraz geçerlilik yöntemi kullanmışlardır. ALS için buldukları doğruluk %97.39 iken myopati olanlar için %86.74 değerini bulmuşlardır (Küçük ve ark., 2019). Mostafa ve ark. (2018), Parkinson hastalığının tanısı için Karar Ağacı, Naive Bayes ve Sinir Ağı (NN) sınıflandırma yöntemlerini uygulamışlar ve üç yöntemin performanslarını değerlendirmişlerdir. Karar Ağacı % 91.63 ile en yüksek doğruluk oranını, Sinir Ağı için % 91.01 ve Naive Bayes'in ise en düşük doğruluk oranı olan % 89.46'lık degeri ürettiğini göstermişlerdir (Mostafa ve ark., 2018). Parkinson hastalığının son tanı yöntemi, ses bozuklukları analizine dayanmaktadır. Bu metodoloji, kayıtlı bir kişinin sesinin özellik kümelerinin çıkarılmasını ve ardından sağlıklı ve Parkinson vakalarını sesden tanımlamak için bir makine öğrenme tekniği kullanılmasını içerir. Mostafa ve ark. (2019), ses bozuklukları analizine dayalı çoklu özellik değerlendirme ve sınıflandırma makinesi öğrenme yöntemlerini test ederek Parkinson hastalığı tanısını iyileştirmeye çalışmışlardır. Çalışmanın amacı, çok etmenli bir sistemin yeni bir çoklu özellikli değerlendirme yaklaşımını önererek soruna en uygun çözümü bulmak olmuştur. Çok özellikli değerlendirme yaklaşımını kullanımdan sonra özneliklere Karar Ağacı, Nave Bayes, Sinir Ağı, Rastgele Ormanlar ve Destek Vektör Makinesi olan beş bağımsız sınıflandırma şemasını uygulamışlar ve sonuçların teşhis doğruluğunu değerlendirmişlerdir. Test sonuçları, çok etmenli sistemin çoklu özellikli değerlendirme yaklaşımının en iyi özellikleri bulunduğu ve sınıflandırıcıların performansını artırdığını göstermiştir. Sınıflandırıcıların teşhis doğruluğunda ortalama iyileşme oranları Karar Ağacı %10.51, Naive Bayes %15.22, Sinir Ağı %9.19, Rastgele Ormanlar %12.75 ve Destek Vektör Makinesi % 9.13' olmuştur (Mostafa ve ark., 2019). Vo ve ark., (2019), meme kanseri sınıflandırmasında en yararlı görsel özellikleri elde etmek için derin öğrenme modellerini kullanan bir yaklaşım önermişlerdir. Hekler ve ark. (2019), insan ve yapay zekayı cilt kanseri sınıflandırması için birleştirmenin potansiyel faydasını araştırmışlardır. 11444 dermoskopik görüntüyü beş tanı kategorisine sınıflandırmak için Konvolüsyonel Sinir Ağlarını (CNN) kullanmışlardır. İnsan ve makine kombinasyonu ile %82.95'lik bir doğruluk elde etmişlerdir (Hekler ve ark., 2019). Zaychenko ve Nafas (2019), tıbbi görüntülerden yararlanılarak ekspres teşhis için gerekli "sütunlu epitel (normal durum); skuamöz epitel (normal durum); serviks uterus epitelyumun metaplazi-benign değişiklikleri; CIN1-hafif dereceli displazi, CIN 2-orta dereceli displazi ve yüksek derecede epitelyal kanserde CIN 3-displazi" şeklindeki altı farklı sınıflandırmanın çözümü için bulanık sinir ağının (NEFClass M) uygulamasını önermişlerdir. NN Geri Yayılımı, RBF NN ve kaskad RBF NN ile karşılaştırmış ve önerilen yaklaşımın etkinlik tahminini yapmışlardır. Bulanık sinir ağının (NEFClass) %90 doğruluk sınıflandırma oranı ile alternatif NN ile karşılaştırıldığında en yüksek doğruluğa sahip olduğunu belirtmişlerdir (Zaychenko ve Nafas, 2019). Gündoğdu ve ark. (2019) yaptıkları çalışmada, bir bulmaca video oyunu sırasında ve oyun öncesinde elde edilen farklı elektrot bölgelerine ait EEG sinyallerini, dalgacık paket dönüşümü kullanarak ayırtmışlar ve güç değerlerini hesaplamışlardır. Sonra K. en yakın komşu algoritması ve farklı yapıdaki ileri beslemeli yapay sinir ağı

sınıflandırıcıları ile baskın olan elektrot bölgesi ve frekans alt bantların belirlenmesini amaçlamışlardır. %83.3 doğru sınıflandırma oranı ile en yüksek başarıyı yapay sinir ağları ile elde etmişlerdir (Gündoğdu ve ark. 2019). Talo ve ark. (2019), normal ve anormal beyin MR görüntülerini otomatik olarak sınıflandırmak için önceden eğitilmiş derin öğrenme CNN mimarisi (ResNet34) kullanan bir yaklaşım önermişlerdir. Önerdikleri modelle, 613 MR görüntüsünde %100 sınıflandırma doğruluğu elde etmişlerdir (Talo ve ark., 2019). Literatürlerde de görüldüğü üzere sınıflandırıcılar son yıllarda da birçok medikal alanda sıkça kullanılmış, popülerliğini hiç kaybetmemiştir.

Çalışılan veri setini oluşturan bu alanda algoritmalarla sınıflandırma işlemi yapan ve çok sayıda sınıflandırıcı kullanarak modellerin doğruluğunu ve performansını karşılaştıran herhangi bir çalışmaya literatürde rastlanmamıştır. Bu çalışmanın amacı, osteoporozla bağlı kifozlu olan hastalara uygulanan egzersiz öncesi ve sonrası iki farklı durumu karakterize edebilecek veri sınıflandırıcılarını yakaladıkları doğruluk oranları, tahmin hızları ve eğitim zamanları açısından karşılaştırmak ve bu alanda birçok sınıflandırma yöntemlerinin uygulanmasına ilişkin derinlemesine bir kavrayış sağlamaktır.

MATERYAL VE METOT

Bu çalışmada kullanılan veriler, osteoporozla bağlı kifozlu olan hastalarda omuz retraksiyon ortezinin (kifoortez) denge üzerine olan etkisinin araştırılması için yapılan bir çalışmadan alınmıştır (Gündoğdu ve ark., 2013). Araştırmacılar, hastaların statik denge performans değerlendirme (SDPD) için Kinesthetic Ability Trainer (KAT 1700 model) cihazı, fonksiyonel mobilite değerlendirme (FMD) için Zamanla Ayağa Kalkma ve Yürüme Testi (Timed Up ve Go testi) kullanmışlardır. Yirmi dokuz hastaya üç ay boyunca osteoporoz (postür, germe ve güçlendirme egzersizleri, eklem hareket açıklığı) egzersizleri ve konvansiyonel denge egzersizleri uygulamışlardır. Değerlendirmeler, egzersiz öncesi (EÖ) ve egzersiz sonrası (ES) üçüncü ayı kapsamaktadır.

Sınıflandırma girişleri için kullanılan öznelik I ve öznelik II değişkenleri sırasıyla SDPD ve FMD skorlarını yansıtmaktadırlar. Karşılaştırma işlemleri, egzersiz öncesi ve egzersiz sonrası 29 hastadan alınan denge skorları kullanılarak yapılmıştır. SDPD ve FMD'lerin öznelik olarak kullanıldığı çalışmada, EÖ ve ES durumları sırasıyla grup I ve grup II olmak üzere iki grupta bir sınıflandırma çalışması yapılmıştır.

Karar ağaçları (decision tree), diskriminant analiz (discriminant analysis), destek vektör makineleri (support vector machines), lojistik regresyon (logistic regression), naive bayes, en yakın komşuluklar (nearest neighbor classifiers), topluluk sınıflandırmaları (ensemble classifiers) ve yapay sinir ağları gibi algoritmalar kullanılarak en iyi sınıflandırma modeli bulunmaya çalışılmıştır. Çalışmada kullanılan veri madenciliği algoritmaları ve Şekil 2-3-4'deki yatay ekseninde verilen rakamlara karşılık gelen sınıflandırıcı türleri Çizelge 1'de gösterilmiştir.

Çizelge 1. Çalışmada kullanılan veri madenciliği algoritmaları (Sınıflandırıcılar)

Algoritmalar	Alt Türleri
Karar ağaçları	1. Hassas 2. Orta ölçekli 3. Kaba
Diskriminant Analiz	4. Doğrusal 5. Kuadratik
Regresyon	6. Lojistik
Naive Bayes	7. Gauss 8. Kernel
Destek Vektör Makineleri	9. Doğrusal 10. Kuadratik 11. Kübik 12. Hassas Gauss 13. Orta ölçekli Gauss 14. Kaba Gauss
En yakın komşuluk Sınıflandırıcı	15. Hassas 16. Orta ölçekli 17. Kaba 18. Kosinüs 19. Kübik 20. Ağırlıklı
Topluluk Sınıflandırıcı	21. Geliştirilmiş 22. Bağlı 23. Altuzay Diskriminant 24. Altuzay KNN 25. RUS Geliştirilmiş Ağaçlar
Yapay Sinir Ağları	26. İleri beslemeli ağ

Karar Ağaçları

Karar ağaçları, birden fazla ortak değişkene dayalı sınıflandırma sistemleri oluşturmak veya bir hedef değişken için tahmin algoritmaları geliştirmede yaygın kullanılan bir veri madenciliği yöntemidir. Bu yöntem bir popülasyonu kök düğümü, iç düğümleri ve yaprak düğümleri ile ters çevrilmiş bir ağaç oluşturan dal benzeri segmentlere ayırır. Algoritma parametrik değildir ve karmaşık bir parametrik yapı oluşturmadan büyük, karmaşık veri kümeleriyle etkili bir şekilde ilgilenebilir (Song ve Lu, 2015). Karar ağacında bulunan iç düğümler öznitelikler üzerinde gerçekleştirilen testleri, dallar test sonuçları ve her bir yaprak düğüm sınıf etiketini temsil etmektedir (Onan, 2015). Otomatik olarak karar ağaç yapısını oluşturmak için geliştirilmiş birçok algoritma bulunmaktadır. Bu algoritmalar, çoğunlukla genelleştirme hatasını en aza indirgeyen en uygun karar ağaç yapısını oluşturmayı hedeflemektedir (Maimon ve Rokach, 2010).

Diskriminant Analizi

Diskriminant analizi, veri kümesindeki değişkenlerin iki veya daha fazla gerçek gruplara ayrılmasına imkan verecek şekilde, birimlerin ya da gözlemlerin p tane özelliği ele alınarak bu birimlerin gerçek gruplarına optimal düzeyde atanmalarını sağlayacak fonksiyonlar oluşturan bir yöntemdir (Sevindik ve Şiray, 2018). Diskriminant analizi (DA), bir Mahalanobis uzaklık hesaplamasına dayalı sınıfları ayırt etmek için kullanılan bir teknik (Dixon ve Brereton, 2009; Morais ve Lima, 2018) olup lineer diskriminant analizi (LDA) veya kuadratik diskriminant analizi (KDA) olmak üzere ikiye ayrılabilir. LDA'da, analiz edilen sınıfların varyans yapıları benzer olarak kabul edildiğinden dolayı diskriminant fonksiyonu sınıflar arasında toplanmış varyans-kovaryans matrisi kullanılarak hesaplanır. Bununla birlikte, KDA'da, her sınıfın farklı bir varyans yapısı olduğu düşünülmektedir; bu nedenle, diskriminant fonksiyonu her sınıf için ayrı ayrı varyans-kovaryans matrisi kullanılarak hesaplanır (Morais ve Lima, 2018). KDA'nın bu özelliği büyük kategori içi varyanslar sergileyen sınıflar analiz edilirken sınıflandırma performansını artırır (Morais ve ark., 2019).

Lojistik Regresyon

Lojistik regresyon bağımlı değişken ikili olduğunda uygundur. Burada bağımsız değişkenler bağımlı değişkenin yordayıcıları olarak kabul edilir. Verileri tanımlamak ve ikili değişken bir bağımlı ile bir veya daha fazla (nominal, sıralı, aralık veya oran ölçeğinde ölçülebilir) bağımsız değişken arasındaki ilişkiyi açıklamak için kullanılır (Kasthuriarachchi ve ark., 2018). Bağımlı değişken ve bağımsız değişkenler arasındaki ilişki doğrusal değildir (Yesilnacar ve Topal, 2005). Lojistik regresyon, genelleştirilmiş doğrusal modelin özel bir durumu olarak düşünülür; bununla birlikte, bağımlı ve bağımsız değişkenler arasındaki ilişki, lineer regresyon modellerinden oldukça farklı varsayımlara dayanmaktadır. Koşullu dağılım Gauss dağılımı yerine Bernoulli dağılımıdır, çünkü bağımlı değişken ikili değişken biçimindedir (Tsangaratos ve Ilia, 2016).

Naive Bayes

Naive Bayes sınıflandırıcı, Bayes teorisine göre tanımlanan bir olasılık modeli kullanarak önceden tanımlanmış bir kategoriye ait yeni bir gözlem olasılığını tahmin eden bir süreçtir (Cheeseman ve Stutz, 1996). Bu model sadeliği ve hızlı çözümler sunması nedeniyle farklı sınıflandırma uygulamalarında yaygın olarak kullanılan bir yöntemdir. Algoritma diğer makine öğrenme algoritmalarına benzer şekilde eğitim için ayrılan zaman serisi veya yatay kesit veriler üzerinden gözlemlerin hangi sınıflara ait olduğunu öğrenir ve yeni gözlemleri genelleştirme yeteneği ile ilgili sınıflara atar (Pabuçcu, 2019).

Destek Vektör Makinesi

Destek vektör makinesi (DVM), sınıfların bir karar sınırına bölündüğü bir sınıflandırma yöntemidir. Sınır tipi özellik sayısına bağlıdır. İki özellikli bir sınıf DVM sınıflandırıcısında karar sınırı bir çizgi olacaktır (Venkata ve Rao, 2019). DVM, bir sınıfın tüm veri noktalarını diğer sınıflardan ayıran en iyi hiper düzlemi bularak verileri sınıflandırır (Vapnik, 2000). DVM için en iyi hiper düzlem, iki sınıf arasında en büyük aralığa sahip olan doğrusal ayırıcı olarak ele alınmaktadır. Aralık, iç veri noktaları bulunmayan hiper düzleme paralel doğrusal ayırıcının maksimum genişliğini ifade eder (Altuntaş ve Kocamaz, 2019).

K-En Yakın Komşu

K-En Yakın Komşu, belirli özelliklere (X) ve ilişkinin değerine (Y) sahip veriler varsa bilinmeyen bir varlığı sınıflandırabilen algoritmalar sınıfındadır (Mitchell, 1997). Parametrik olmayan bir öğrenme algoritmasıdır. Sınıflandırılması istenen bir verinin en yakın k komşuluktaki verileri temel alarak sınıflandırıldığı bir yöntemdir. Bu algoritmada sınıfı bilinmeyen bir verinin, k en yakın komşulara olan benzerlikleri hesaplanır ve sınıflara ataması gerçekleştirilir. Bu algoritmada eğitim aşaması çok hızlı olmasına rağmen test kısmı hem bellek hem de zaman açısından maliyetlidir (Saini ve ark., 2013).

Topluluk Sınıflandırıcı

Topluluk sınıflandırıcı algoritmaları, veri kümesinin farklı alt kümeleri üzerinde eğitilmiş temel sınıflandırıcılar tarafından üretilen çıktılarının kombinasyonuna izin verir. Bir sınıflandırma topluluğu, birden çok sınıflandırma modelin ağırlığı ile oluşan bir kombinasyondur. Ayrıca, makine öğrenme algoritma toplulukları mevcut veri kaynaklarını güncelleyebileceğinden, bunları yeni veya güncellenmiş veriler üzerinde kullanma olasılığı vardır. Böylece, tüm topluluğu yeniden eğitmeye gerek yoktur. Topluluk yöntemleri, yanlış alarmların azaltılması ve doğruluk artışına yüksek etkisi ile çok verimli olabilir. Sınıflandırıcıları birleştirme kavramı, ayrı sınıflandırıcı performanslarının iyileştirilmesi için yeni bir yön belirlemiştir. Genel olarak çoklu sınıflandırma modellerinin birleştirilmesi öngörücü performansı artırır (Timcenko ve Gajin, 2017).

Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beyninin bilgi işleme tekniğinden esinlenerek ortaya çıkan ve çok sayıda sinir hücrelerinin ağ içerisinde çeşitli şekillerde birbirine bağlanarak oluşturduğu öğrenme şeklini referans alan yapay zeka yöntemlerinden birisidir. YSA tahmin yapma, kestirim, sınıflandırma gibi birçok problemde yaygın olarak kullanılan etkili bir öğrenme metodudur. Günümüzde YSA kullanan sistemler, genellikle çok katmanlı ileri beslemeli ağ modelini ve ağın eğitilmesi için ise geriye yayılım algoritmasını kullanmaktadırlar (Kou ve ark., 2013; Dandil ve Gürgen, 2019).

Yukarıda anlatılan ve çalışmada uygulanan sınıflandırıcıların ilgili parametre ayarları için varsayılan (default) değerler kullanılmış ve Çizelge 2'de gösterilmiştir.

Verilerin sınıflandırılmasında modellerin eğitimi ve tüm testler MATLAB programı vasıtasıyla gerçekleştirilmiştir. Model doğrulaması için doğrulaması olmayan, Holdout ve K Katlamalı Çapraz Doğrulama (K-KÇD) şeklinde üç seçenek mevcuttur. K- KÇD'de, veri kümesi eşit olarak K bölümlerine ayrılarak bunların bir bölümü doğrulama diğer kalan kısmı ise ön eğitim olarak kullanılmaktadır. Eğitim seti modelin eğitildiği veriler iken; test seti ise modelin eğitilmeyen veriler üzerinde ne kadar iyi performans gösterdiğini görmek için kullanılmaktadır. Hold-Out yöntemi, veri kümesinin rastgele iki ayrı veri kümesine bölündüğü, sınıflandırıcının bilgi çıkarmaya çalıştığı ilk küme ve ikinci kümenin test edilen çıkarılan bilgiler için kullanıldığı yüzde bölme yöntemidir (Verma vd, 2020). Hold-out, veri setini eğitim ve test kümesi olarak ikiye ayırma yöntemidir. Bu çalışmada eğitim için Hold-out yaklaşımı

kullanılmış olup verilerin %80'i eğitim %20'si de test için ayrılmıştır. Modeller eğitildikten sonra elde edilen test sonuçları doğruluk oranları, tahmin hızı ve eğitim zamanı kullanılarak değerlendirilmiştir. Sınıflandırıcı performans karşılaştırılmasında kullanılan doğruluk oranının matematiksel ifadesi Denklem 1'de gösterilmiştir (Zeng ve ark., 2010).

$$\text{Doğruluk oranı} = \frac{\text{Doğru sınıflandırılan örnek sayısı}}{\text{Toplam örnek sayısı}} \quad (1)$$

Çizelge 2. Çalışmada kullanılan sınıflandırıcılara ait parametre ayarları

Algoritmalar	Alt türleri	Parametre ayarları
Karar ağaçları	Hassas	Maksimum bölme sayısı: 100, Bölünmüş kriter: Gini'nin çeşitlilik indeksi, Vekil karar bölmeleri: Off
	Orta ölçekli	Maksimum bölme sayısı: 20, Bölünmüş kriter: Gini'nin çeşitlilik indeksi, Vekil karar bölmeleri: Off
	Kaba	Maksimum bölme sayısı: 20, Bölünmüş kriter: Gini'nin çeşitlilik indeksi, Vekil karar bölmeleri: Off
Diskriminant analiz	Doğrusal	Kovaryans yapısı: Tam
	Kuadratik	Kovaryans yapısı: Tam
Regresyon	Lojistik	
Naive Bayes	Gauss	Sayısal tahminciler için dağıtım adı: Gaussian
	Kernel	Sayısal tahminciler için dağıtım adı: Kernel, Çekirdek tipi: Gauss Destek: Sınırsız
Destek vektör makineleri	Doğrusal	Çekirdek işlevi: Doğrusal, Çekirdek ölçeği: Otomatik, Kutu kısıtlama seviyesi: 1
	Kuadratik	Çekirdek işlevi: Kuadratik, Çekirdek ölçeği: Otomatik, Kutu kısıtlama seviyesi: 1
	Kübik	Çekirdek işlevi: Kübik, Çekirdek ölçeği: Otomatik, Kutu kısıtlama seviyesi: 1
	Hassas Gauss	Çekirdek işlevi: Hassas Gauss, Çekirdek ölçeği: 0.25, Kutu kısıtlama seviyesi: 1
	Orta ölçekli Gauss	Çekirdek işlevi: Orta ölçekli Gauss, Çekirdek ölçeği: 1, Kutu kısıtlama seviyesi: 1
K-en yakın komşu	Kaba Gauss	Çekirdek işlevi: Kaba Gauss, Çekirdek ölçeği: 4, Kutu kısıtlama seviyesi: 1
	Hassas	Komşu sayısı: 1, Mesafe metriği: Öklid, Mesafe ağırlığı: Eşit
	Orta ölçekli	Komşu sayısı: 10, Mesafe metriği: Öklid, Mesafe ağırlığı: Eşit
	Kaba	Komşu sayısı: 100, Mesafe metriği: Öklid, Mesafe ağırlığı: Eşit
	Kosinüs	Komşu sayısı: 10, Mesafe metriği: Kosinüs, Mesafe ağırlığı: Eşit
	Kübik	Komşu sayısı: 10, Mesafe metriği: Minkowski (kübik), Mesafe ağırlığı: Eşit
Topluluk sınıflandırıcı	Ağırlıklı	Komşu sayısı: 10, Mesafe metriği: Öklid, Mesafe ağırlığı: Kare ters
	Geliştirilmiş	Topluluk yöntemi: AdaBoost, Öğrenci tipi: Karar ağacı, Maksimum bölme sayısı: 20, Öğrenci sayısı: 30, Öğrenme oranı: 0.1
	Bağlı	Topluluk yöntemi: Bag, Öğrenme tipi: Karar ağacı, Maksimum bölme sayısı: 57, Öğrenci sayısı: 30
	Altuzay Diskriminant	Topluluk yöntemi: Altuzay, Öğrenci tipi: Ayrımcı, Öğrenci sayısı: 30, Altuzay boyutu: 1
Yapay Sinir ağları	Altuzay KNN	Topluluk yöntemi: Altuzay, Öğrenci tipi: En yakın komşular, Öğrenci sayısı: 30
	RUS Geliştirilmiş Ağaçlar	Topluluk yöntemi: RUSBoost, Öğrenci tipi: Karar ağacı, Maksimum bölme sayısı: 20, Öğrenci sayısı: 30, Öğrenme oranı: 0.1
	İleri beslemeli ağ	Ağ eğitimi: Levenberg-Marquardt, Gizli katman sayısı:2, Gizli katmanlardaki nöron sayısı:15

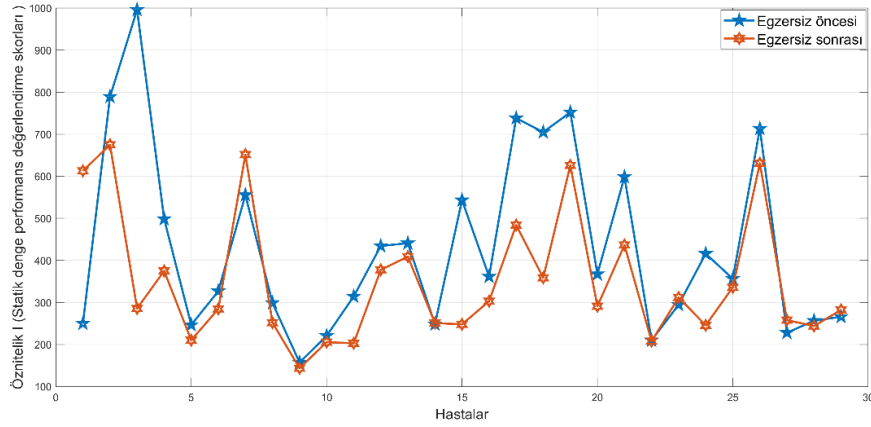
BULGULAR VE TARTIŞMA

Çalışmaya katılan gönüllülerin yaş ortalaması 69.86±5.38 yıl, boy uzunluğu ortalaması 151.76±7.56 cm'dir. 29 gönüllünün egzersiz öncesi ve sonrasına ait SDPD ve FMD skorları (öznitelikleri), Şekil 1'de gösterilmiştir. Gönüllülerin statik denge ve fonksiyonel mobilite değerlendirilmesi için kullanılan denge skorlarına ait istatistiksel değerler ise Çizelge 3'de gösterilmiştir.


Çizelge 3. Denge skorlarına ait ortalama ve standart sapma değerleri

	Grup I (EÖ)		Grup II (ES)	
	SDPD	FMD	SDPD	FMD
Ortalama	433.97	14.12	351.76	11.14
Standart Sapma	215.71	4.45	153.14	2.90

Osteoporozla Bağlı Kifozlu Hastalara Uygulanan Egzersizlerin Oluşturduğu Denge Değişikliklerine İlişkin Veriler Kullanılarak Yapay Sinir Ağlarının Diğer Sınıflandırma Algoritmalarıyla Karşılaştırılması



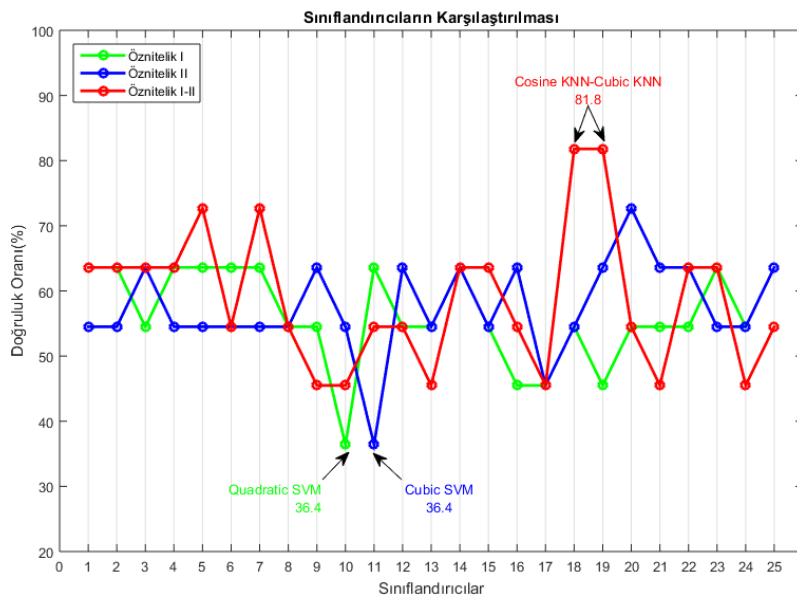
(a)



(b)

Şekil 1. 29 hastanın egzersiz öncesi ve sonrasına ait (a) SDPD ve (b) FMD skorları (öznitelikleri)

Öznitelik I, öznitelik II ve öznitelik I+öznitelik II (öznitelik I+II) tüm öznitelik varyasyonları, 25 farklı sınıflandırma algoritmasına giriş olarak uygulanmış ve sonuçlara göre algoritma karşılaştırmaları yapılmıştır. Öznitelik seçimlerine göre sınıflandırıcıların başarı oranlarını gösteren grafik Şekil 2’de gösterilmiştir.



Şekil 2: 25 farklı algoritmanın doğruluk oranlarına göre sınıflandırma sonuçları

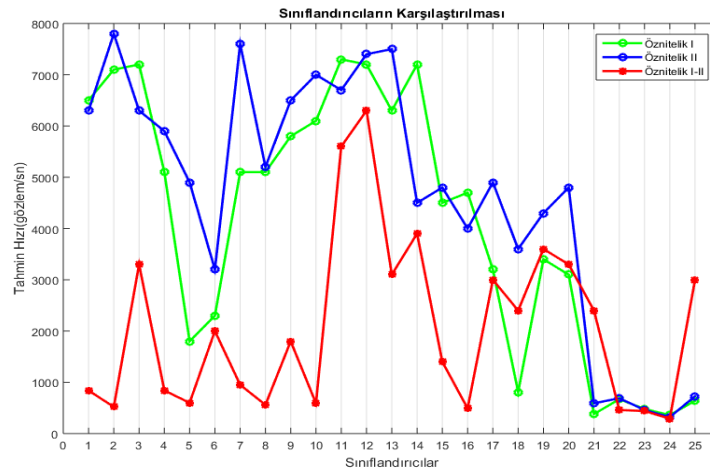
Ayrıca öznitelik seçimlerine göre sınıflandırıcıların başarı oranlarıyla ilgili istatistiksel hesaplamalar, Çizelge 4’de sunulmuştur. Tablodaki istatistiksel değerler incelendiğinde; en başarılı sınıflandırma tahminlerin özniteliklerin ikisinin beraber kullanıldığı durumlarda ortaya çıktığı görülmüştür.

Çizelge 4. Sınıflandırıcıların öznitelik seçimine göre doğruluk oranlarına ilişkin istatistikler

	Minimum	Maksimum	Ortalama	Standart Sapma
Öznitelik I	36.4	63.6	56.3	7.4
Öznitelik II	36.4	72.7	57.4	7.3
Öznitelik I+II	45.5	81.8	58.9	10.8

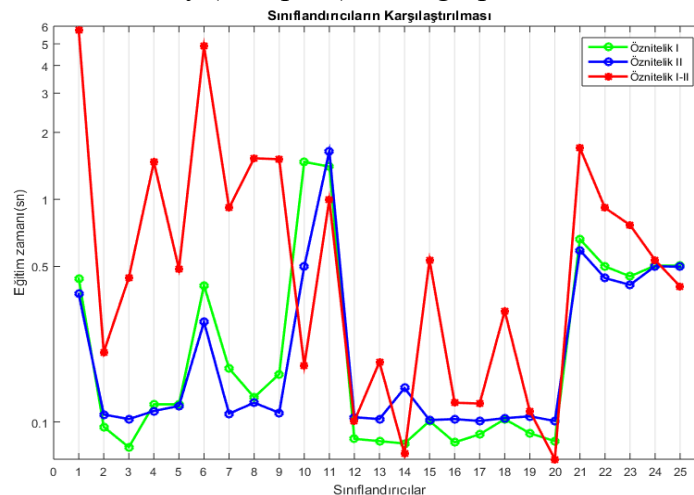
Sınıflandırıcılar karşılaştırıldığında; %81.8 ile en yüksek başarı oranı öznitelik I +II’nin giriş yapıldığı Kosinüs (Cosine) KNN ve Kübik (Cubic) KNN algoritmaları; en düşük başarı oran ise % 36.4 ile öznitelik I’nin giriş yapıldığı Kuadratik (Quadratic) DVM ve öznitelik II’nin giriş yapıldığı Kübik (Cubic) DVM algoritması ile elde edilmiştir.

Şekil 3 ve Şekil 4’de, öznitelik seçimlerine göre sınıflandırıcıların sırasıyla tahmin hızı ve eğitim zamanı ile ilgili karşılaştırmaları gösteren grafikler verilmiştir.



Şekil 3: Tahmin hızlarına göre 25 algoritmanın sınıflandırma sonuçları

Sınıflandırıcılar tahmin hızına göre karşılaştırıldığında (giriş olarak öznitelik I+II seçildiğinde); en hızlı tahmin 6300 gözlem/sn ile Hassas Gauss (Fine Gaussian) DVM algoritması olurken en düşük hızlı tahminin ise 290 gözlem/sn ile Altuzay (Subspace) KNN grup sınıflandırıcısı olduğu görülmüştür.



Şekil 4: Eğitim zamanına göre 25 algoritmanın sınıflandırma sonuçları

Tüm öznitelik varyasyonları için ortak olan durum; topluluk sınıflandırıcıların eğitimi için daha fazla zamana ihtiyaç duyulduğunun ortaya çıkmasıdır (Şekil 4).

Ayrıca, 6 sınıflandırıcı algoritmasında kendi içlerinde farklı parametreler ile oluşturulmuş modellerin performansları kıyaslanmış ve Çizelge 5’de sunulmuştur.

Çizelge 5. Farklı parametreler ile oluşturulmuş modellerin performansları

Algoritma (model sayısı)	Öznitelik I		Öznitelik II		Öznitelik I+II	
	En düşük	En yüksek	En düşük	En yüksek	En düşük	En yüksek
Karar ağaçları (3)	Kaba	Orta ölçekli	Hassas	Kaba	Hassas	Orta ölçekli
Diskriminant analiz (2)	Doğrusal	Kuadratik	Doğrusal	Kuadratik	Doğrusal	Kuadratik
Naive Bayes (2)	Kernel	Gauss	Kernel	Gauss	Kernel	Gauss
Destek vektör makineleri (6)	Kuadratik	Kaba Gauss	Küçük	Kaba Gauss	Doğrusal	Kaba Gauss
K-en yakın komşu (6)	Kaba	Ağırlıklı	Kaba	Ağırlıklı	Kaba	Küçük
Topluluk sınıflandırıcı (5)	Geliştirilmiş	Altuzay	Altuzay KNN	RUS Geliştirilmiş iş Ağaçlar	Geliştirilmiş	Altuzay
		Diskriminant				Diskriminant

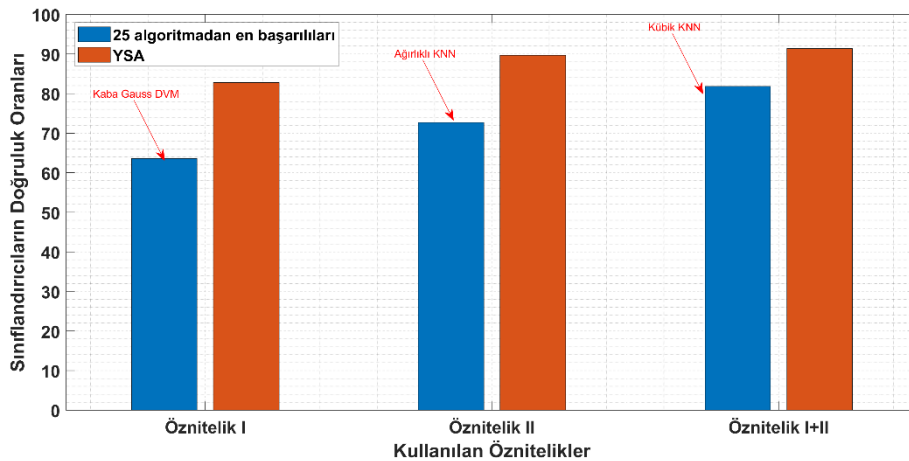
Sınıflandırma işlemi yukarıda belirtilen 25 algoritma ile yapılan çalışmalara ek olarak aynı şartlarda ileri beslemeli yapay sinir ağları kullanılarak da gerçekleştirilmiştir. Tüm veri randomize bir şekilde %80 eğitim ve %20 test verisi olarak kendi içinde ayrılmıştır. Oluşturulan YSA’nın sahip olduğu her iki gizli katmanda 15 nöron vardır. Ağ eğitimi için Levenberg-Marquardt algoritması kullanılmıştır.

Sınıflandırma başarısını gösteren doğruluk oranı ve eğitim zamanını kullanılarak yapay sinir ağının diğer 25 algoritma içinde en başarılıları ile karşılaştırma işlemi, Çizelge 6 ve Şekil 5’de sunulmuştur.

Çizelge 6. Sınıflandırıcının doğruluk oranları ve eğitim sürelerine göre karşılaştırılması

	25 algoritma içinde en başarılı sınıflandırıcılar			Yapay Sinir Ağları Sınıflandırıcısı	
	Sınıflandırıcı Türü	Doğruluk Oranı	Eğitim Zamanı(s)	Doğruluk Oranı	Eğitim Zamanı(s)
Öznitelik I	Kaba Gauss DVM	63.6	0.080	82.8	14.524
Öznitelik II	Ağırlıklı KNN	72.7	0.101	89.7	5.085
Öznitelik I+II	Küçük KNN	81.8	0.112	91.4	2.372

**DVM: Destek vektör makinesi, KNN: K en yakın komşuluk



Şekil 5: Önerilen YSA yönteminin 25 algoritmadan en başarılıları ile kıyaslanması

Önerilen yapay sinir ağları modeli, doğruluk başarı oranına göre, diğer 25 algoritmanın en başarılıları ile kıyaslandığında; Kaba Gauss DVM modeline göre %30 (giriş olarak öznitelik I), ağırlıklı KNN modeline göre %23 (öznitelik II) ve Küçük KNN modeline göre %12 (öznitelik I+II) daha iyi sonuçlar vermiştir. Sınıflandırıcı olarak önerilen yönteminin, diğer 25 algoritmaya göre daha fazla tatmin ettiği görülmüştür.

Yapılan bu çalışmada önerilen ve iyi bir sınıflandırma yöntemi olan (Karadağ ve ark., 2020) YSA sınıflandırma modeli, literatürdeki kullanılan diğer modellerle kıyaslandığında yüksek sınıflandırma

oranına sahip olduğu görülmektedir. Yapay sinir ağları yöntemi, doğruluk başarı oranı açısından en iyi sonuçlar vermesi ile birlikte eğitim için diğer başarılı algoritmalara göre daha fazla zaman harcadığı görülmüştür.

SONUÇ

Bu çalışma, osteoporozla bağlı kifozlu olan hastalara uygulanan egzersizlerden kaynaklanan denge skorları kullanılarak egzersiz öncesi ve sonrası iki farklı durumun sınıflandırılmasında farklı algoritma yaklaşımlarını sunmaktadır. Statik denge ve fonksiyonel mobilite performans skorları kullanılarak sınıflandırma tahmini için karşılaştırmalı bir çalışma yapılmıştır. Eğitim için Hold-out yaklaşımı kullanılmış olup verilerin %80'i eğitim %20'si de test için ayrılmıştır. Sınıflandırmada doğruluk başarı oranı en yüksek olan ve eğitim için en fazla zaman harcayan (iki özelliğin aynı anda giriş olarak kullanıldığı) yapay sinir ağları tekniği olduğu görülmüştür. Bu teknik denge değerlerine bakarak %91.4 doğruluk oranı ile katılımcıların egzersiz yaptıklarını anlayabilmiştir. Yapay sinir ağları ile oluşturulacak sınıflandırıcılar, fiziksel tedavi ve rehabilitasyon amaçlı uygulanan egzersizlerin denge üzerine etkisini görmek için kullanılabilir. İleriki çalışmalarda, yapay sinir ağı parametreleri üzerinde daha detaylı denemeler yapılarak sınıflandırma doğruluğunun artırılması hedeflenmektedir.

TEŞEKKÜR

Bu çalışmada kullanılan veri setini oluşturmada emeği geçen ve benimle paylaşan Gündoğdu ve diğer çalışma arkadaşlarına çok teşekkür ederim.

Çıkar Çatışması

Herhangi bir çıkar çatışması olmadığını beyan ederim.

Yazar Katkısı

Makalenin planlama, yürütme ve yazımının tarafımdan yapıldığını beyan ederim.

KAYNAKLAR

- Alkan BM, Fidan F, Tosun A, Ardiçoğlu Ö, 2011. Fiziksel Tıp ve Rehabilitasyon Polikliniğimize Başvuran Hastalarda Osteoporoz İnsidansı. *Türk Osteoporoz Dergisi*, 17: 10-13.
- Altuntaş Y, Kocamaz AF, 2019. Renk Momentleri ve Destek Vektör Makineleri Kullanarak Haploid Mısır Tohumlarının Tanımlanmasında Renk Uzaylarının Sınıflandırma Performansına Etkisinin Karşılaştırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31 (2): 551-560.
- Bonner FJ, Chesnut CH, Lindsay R, 2005. Osteoporosis. In: *Delisa's Physical Medicine and Rehabilitation*. Lippincott Williams and Wilkins No: 4, pp. 699-719, Philadelphia-USA.
- Cheeseman P, Stutz J, 1996. Bayesian Classification (Autoclass): Theory and Results. In: *Advances in Knowledge Discovery and Data Mining*. American Association for Artificial Intelligence Press, pp. 153-180, California-USA.
- Dandıl E, Gürgen E, 2019. Yapay Sinir Ağları Kullanılarak Fotovoltaik Panel Güç Çıkışlarının Tahmini ve Sezgisel Algoritmalar ile Karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*, 16: 146-158.
- Dixon SJ, Breerton RG, 2009. Comparison of Performance of Five Common Classifiers Represented as Boundary Methods: Euclidean Distance to Centroids, Linear Discriminant Analysis, Quadratic Discriminant Analysis, Learning Vector Quantization and Support Vector Machines, as Dependent on Data Structure. *Chemometrics Intelligent Laboratory Systems*, 95 (1): 1-17.
- Erkmen N, Suveren S, Göktepe AS, Yazıcıoğlu K, 2007. Farklı Branşlardaki Sporcuların Denge Performanslarının Karşılaştırılması. *Sporometre Beden Eğitimi ve Spor Bilimleri Dergisi*, 5 (3): 115-122.
- Eskiyurt N, 2005. Osteoporoz Rehabilitasyonu. *Osteoporoz*, Güneş Kitabevi, s. 259-291, Ankara-Türkiye.

- Gündoğdu M, Öncel S, Şahin E, Baydar M, Dilek B, 2013. Osteoporozla Bağlı Kifozlu Olan Hastalarda Omuz Retraksiyon Ortezinin Denge, Kifoz Açısı ve Yaşam Kalitesi Üzerine Etkisi. *Turkish Journal of Geriatrics*, 16 (3): 253-259.
- Gündoğdu S, Çolak ÖH, Doğan EA, Gülbetkin E, Polat Ö, 2019. Bir Bulmaca Video Oyunu Oynama Sürecinde Baskın EEG Frekans Alt Bandların Belirlenmesi. *Tıp Teknolojileri Kongresi (TIPTEKNO)*, 3-5 Ekim 2019, Kuşadası.
- Harrington P, 2012. *Machine Learning in Action*. Manning Publications No: 1, pp. 3-17, New York-USA.
- Hekler A, Utikal JS, Enk AH, Hauschild A, Weichenthal M, Maron RC, Berking C, Haferkamp S, Klode J, Schadendorf D, Schilling B, Holland-Letz T, Izar B, Kalle CV, Fröhling S, Brinker TJ, 2019. Superior Skin Cancer Classification by the Combination of Human and Artificial Intelligence. *European Journal of Cancer*, 120: 114-121.
- Karadağ K, Tenekeci ME, Gümüşçü A, 2020. Yapay Sinir Ağları Kullanılarak İmleç Yönü Tespiti. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 9 (1): 172-179.
- Kasthuriarachchi, KTS, Liyanage, SR, Bhatt CM, 2018. A Data Mining Approach to Identify the Factors Affecting the Academic Success of Tertiary Students in Sri Lanka. In: *Software Data Engineering for Network eLearning Environments*, Springer International Publishing No: 1, pp. 178-197, New York-USA.
- Kou J, Liu J, Li Q, Fang W, Chen Z, Liu L, Guan T, 2013. Photovoltaic Power Forecasting Based on Artificial Neural Network and Meteorological Data. *2013 IEEE International Conference of IEEE Region 10 (TENCON 2013)*, Xian, October 22-25, 2013, pp:1-4.
- Küçük H, Eminoğlu İ, Balcı K, 2019. Nöromusküler Hastalıkların Yapay Zeka Yöntemleri ile Sınıflandırılması. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (4): 1725-1741.
- Maimon O, Rokach L, 2010. *Classification Trees*. In: *Data Mining and Knowledge Discovery Handbook*, Springer No: 2, pp. 149-174, New York-USA.
- Mitchell TM, 1997. *Machine Learning*. McGraw-Hill, New York-USA.
- Morais CLM, Lima KMG, 2018. Principal Component Analysis with Linear and Quadratic Discriminant Analysis for Identification of Cancer Sample Based on Mass Spectrometry. *Journal of the Brazilian Chemical Society*, 29 (3): 472-481.
- Morais CLM, Lima KMG, Martin FL, 2019. TTWD-DA: A MATLAB Toolbox for Discriminant Analysis Based on Trilinear Three-Way Data. *Chemometrics Intelligent Laboratory Systems*, 188: 46-53.
- Mostafa SA, Mustapha A, Khaleefah SH, Ahmad MS, Mohammed MA, 2018. Evaluating the Performance of Three Classification Methods in Diagnosis of Parkinson's Disease. *Proceedings of the Third International Conference on Soft Computing and Data Mining (SCDM 2018)*, Johor, February 06-07, 2018, pp:43-52.
- Mostafa SA, Mustapha A, Mohammed MA, Hamed RI, Arunkumar N, Ghani MKA, Jaber MM, Khaleefah SM, 2019. Examining Multiple Feature Evaluation and Classification Methods for Improving the Diagnosis of Parkinson's Disease. *Cognitive Systems Research*, 54: 90-99.
- Onan Y, 2015. Şirket İflaslarının Tahmin Edilmesinde Karar Ağacı Algoritmalarının Karşılaştırmalı Başarım Analizi. *Bilişim Teknolojileri Dergisi*, 8 (1): 9-19.
- Pabuççu H, 2019. Borsa Endeksi Hareketlerinin Tahmini: Trend Belirleyici Veri. *Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi*, 22 (1): 246-256.
- Saini I, Singh D, Khosla A, 2013. QRS Detection Using K-Nearest Neighbor Algorithm (KNN) and Evaluation on Standard ECG Databases. *Journal of Advanced Research*, 4 (4): 331-344.
- Sevindik S, Şiray GÜ, 2018. Diskriminant Analizi ve Bazı Alternatif Regresyon Analizleri. *Çukurova Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 35 (9):117-125.
- Sinaki M, Brey RH, Hughes CA, Larson DR, Kaufman KR, 2005. Balance disorder and Increased Risk of Falls in Osteoporosis and Kyphosis: Significance of Kyphotic Posture and Muscle Strength. *Osteoporosis International*, 16 (8):1004-1010.
- Sindel D, 2002. Tanı Yöntemleri. *Türkiye Klinikleri Fiziksel Tıp ve Rehabilitasyon Dergisi*, 2:17-29.

- Song Y-Y, Lu Y, 2015. Decision Tree Methods: Applications for Classification and Prediction. Shanghai Archives of Psychiatry, 27 (2):130-135.
- Talo M, Baloglu UB, Yıldırım Ö, Achary UR, 2019. Application of Deep Transfer Learning for Automated Brain Abnormality Classification Using MR Images. Cognitive Systems Research, 54: 176-188.
- Timcenko V, Gajin S, 2017. Ensemble Classifiers for Supervised Anomaly Based Network Intrusion Detection. 13th IEEE International Conference on Intelligent Computer Communication and Processing (ICCP), Cluj-Napoca, September 07-09, pp:13-19.
- Tosun A, Bölükbaşı N, 2004. Osteoporoz ve Egzersiz, Türkiye Klinikleri Fiziksel Tedavi Rehabilitasyon Dergisi, 4: 7-10.
- Tsangaratos P, Ilia I, 2016. Comparison of a Logistic Regression and Naïve Bayes Classifier in Landslide Susceptibility Assessments: The Influence of Models Complexity and Training Dataset Size. Catena, 145 (2016):164–179.
- Vapnik V, 2000. The Nature of Statistical Learning Theory. Springer-Verlag No: 2, New York-USA
- Venkata SK, Rao S, 2019. Fault Detection of a Flow Control Valve Using Vibration Analysis and Support Vector Machine, Electronics, 8 (1062): 1-15.
- Verma C, Stoffaova V, Illes Z, 2020. Prediction of Residence Country of Student Towards Information, Communication and Mobile Technology for Real-Time: Preliminary Results. Procedia Computer Science, 167: 224–234.
- Vo DM, Quang NQ, Lee SW, 2019. Classification of Breast Cancer Histology Images Using Incremental Boosting Convolution Networks. Information Sciences, 482:123-138.
- Walker-Bone K, Dennison E, Cooper C, 2001. Epidemiology of Osteoporosis. Rheumatic Disease Clinics of North America, 27 (1): 1-18.
- Yesilnacar E, Topal T, 2005. Landslide Susceptibility Mapping: a Comparison of Logistic Regression and Neural Networks Methods in a Medium Scale Study, Hendek Region (Turkey). Engineering Geology, 79 (3–4): 251–266.
- Yılmaz H, Erkin G, Polat HAD, Küçükşen S, Sallı A, Uğurlu H, 2012. Osteoporozda Yaşam Kalitesi: Bir Kontrollü Çalışma. Turkish Journal of Osteoporosis, 18 (2): 47-52.
- Zaychenko Y, Nafas AAGO, 2019. Medical Images Classification and Diagnostics Using Fuzzy Neural Networks. American Journal of Neural Networks and Applications, 5 (2): 45-50.
- Zeng XD, Chao S, Wong F, 2010. Optimization of Bagging Classifiers Based on SBCB algorithm. Proceedings of the Ninth International Conference on Machine Learning and Cybernetics, Qingdao, July 11-14, pp.262-267.