



Regresyon Ağaçları ve Çoklu Doğrusal Regresyon Analizlerinin PISA 2022 Matematik Okuryazarlığı Becerisini Yordama Performanslarının İncelenmesi

Examining the Performance of Regression Trees and Multiple Linear Regression Analyses in Predicting PISA 2022 Mathematical Literacy Skills

Fatma Nur AYDIN

Dr. ◆ Millî Eğitim Bakanlığı ◆ fatmanuraydin.2012@gmail.com ◆ ORCID: 0000-0003-0887-395X

Kübra ATALAY KABASAKAL

Doç. Dr. ◆ Hacettepe Üniversitesi, Eğitim Fakültesi ◆ kkatalay@gmail.com ◆ ORCID: 0000-0002-3580-5568

Özet

Araştırmada çoklu doğrusal regresyon analizinin ve regresyon ağacı algoritmasının PISA 2022 matematik okuryazarlığı becerisini yordama performanslarına ilişkin kestirimler yapılmıştır. Buna ek olarak yordamada önemli olan değişkenlerin tespiti gerçekleştirilmiştir. Buna göre 6645 kişinin verileri kullanılmıştır. Bağımsız değişkenler olarak dijital kaynakların kullanımı ile ilgili iki anket maddesi, haftalık ders saati sayısı, matematik öz yeterliliğine ilişkin iki farklı indeks, matematiksel kavramlara aşinalık, Bilgi ve İletişim Teknolojisi kaynakları, ev olanakları, ekonomik, sosyal ve kültürel statü indeksi, okuduğunu anlama becerisine ilişkin birinci olası değer kullanılmıştır. Tahmin performansları ortalama mutlak hata, ortalama mutlak hata yüzdesi, hata kareler ortalaması, hata kareler ortalamasının kökü, yanlışlık, beklenen ve gözlenen değerler arasındaki korelasyon ve açıklanan varyans metriklerine göre karşılaştırılmıştır. Elde edilen sonuçlara göre (1) her iki yöntemin tahmin performansı iyi düzeyde olmakla birlikte, çoklu doğrusal regresyon analizi daha iyi performans göstermiştir. (2) Her iki yöntemde değişkenlerin önem sıralaması büyük ölçüde benzer olmakla birlikte, en önemli iki değişken okuduğunu anlama puanı ve formal ve uygulamalı matematiğe yönelik öz yeterlik düzeyi olmuştur.

Anahtar Kelimeler: Regresyon ağacı, Çoklu doğrusal regresyon, PISA 2022, Matematik okuryazarlığı

Abstract

The study made predictions regarding the performance of multiple linear regression analysis and regression tree algorithm in predicting PISA 2022 mathematical literacy skills. In addition, the variables that are important in prediction were identified. Accordingly, data from 6645 individuals were used. As independent variables, two questionnaire items related to the use of digital resources, the number of weekly class hours, two different indices of mathematics self-efficacy, familiarity with mathematical concepts, ICT resources, home possessions, economic, social and cultural status index, and the first plausible value for reading literacy skills were used. Prediction performances were compared according to the metrics of mean absolute error, mean absolute error percentage, mean squared error, root mean squared error, bias, correlation between expected and observed values and explained variance. According to the results obtained, (1) although the prediction performance of both methods was good, multiple linear regression analysis showed better performance. (2) Although the importance ranking of the variables was largely similar in both methods, the two most important variables were reading literacy score and self-efficacy level towards formal and applied mathematics.

Keywords: Regression tree, Multiple linear regression, PISA 2022, Mathematics literacy

1. Giriş

Günümüzde çeşitli kararlar yapay zekâ ve veri bilimindeki gelişmelerle birlikte karmaşık otomatik sistemler vasıtasıyla alınmaktadır. Dolayısıyla çeşitli girdi verileriyle tahmin yapmaya yönelik olan makine öğrenme modellerinin çalışma prensiplerinin anlaşılması giderek daha önemli hale gelmektedir (Redelmeier ve diğerleri, 2020). Bu kapsamda değerlendirilebilecek veri madenciliği ise büyük veri setlerini analiz etmek amacıyla bilgisayar bilimleri ve istatistikte geliştirilen teknikler için kullanılan genel bir kavramdır (Strobl, 2013). Öte yandan eğitsel veri madenciliği ise eğitim alanından gelen ham verilerin yine eğitim araştırmalarında kullanılabilir faydalı bilgilere dönüştürülmesi sürecini kapsar (Romero & Ventura, 2010).

Makine öğrenme yöntemlerinden olan sınıflandırma ve regresyon ağaçları (SRA) Breiman ve diğerleri (1984) tarafından geliştirilmiştir. SRA'lar bağımlı değişkenin değerini bağımsız değişkenlerden faydalanarak yordamayı içeren parametrik olmayan regresyon yöntemlerindedir (Strobl, 2013). Bağımlı değişkenin sürekli olması durumunda regresyon, kategorik olması durumunda ise sınıflandırma ağaçları elde edilir (Hastie ve diğerleri, 2009). Bu yöntemlerde kullanılan bölme kuralları bir ağaç şeklinde gösterilebildiği için "karar ağacı" yöntemleri olarak bilinirler (James ve diğerleri, 2013). Veri analizinde zaman alan bir süreç olan veri ön işleme gibi adımları gerektirmemesi SRA yöntemlerinin en önemli avantajlarından biridir (Hastie ve diğerleri, 2009). Parametrik tekniklerde olmayan bu avantajlar arasında; tüm ölçek türlerindeki değişkenleri ele alabilmeleri, eksik verilerle başa çıkabilmeleri, değişken önemini değerlendirmek için ölçütler sunabilmeleri (Breiman ve diğerleri, 1984, Steinberg & Colla, 1995), bağımsız değişkenlerdeki uç değerlere karşı sağlam olmaları, bağımsız değişkenlerin monoton dönüşümlerinden etkilenmemeleri, büyük örneklemelerde de hesaplama yapabilmeleri, bölme kurallarını belirlemek için aşamalı bir yöntem kullanılması sebebiyle değişkenlerin önceden seçilmesine gerek olmadan ilgisiz bağımsız değişkenlerle başa çıkabilmeleri (Breiman ve diğerleri, 1984; Hastie ve diğerleri, 2009; Steinberg & Colla, 1995), yorumlanmalarının kolay olması (James ve diğerleri, 2013) sıralanabilir.

Bir regresyon ağacı (RA) hata kareler toplamındaki azalmayı maksimize edecek şekilde düğümlerin (bölünmenin gerçekleştiği her alt grup) tekrarlı olarak bölünmesiyle oluşturulur (Breiman ve diğerleri, 1984). RA'nın oluşturulma aşamaları Yohannes & Webb (1999) tarafından dört adımda açıklanmıştır:

1. Kök düğümden (ağacın en tepesindeki düğüm) başlayarak tüm bağımsız değişkenler üzerinden tüm olası bölünmelerin gerçekleştirilmesi ve her bölünmeye düğüm safsızlık ölçütünün uygulanarak safsızlıktaki azalmanın belirlenmesi.

2. Bölünme iyiliği kriterinin uygulanarak en iyi bölünmenin seçilmesi ve sağ/sol alt düğümlerin oluşturulması.

3. Terminal olmayan (daha fazla bölünebilen düğüm) her düğüm için 1. ve 2. adımların tekrar uygulanmasıyla mümkün olan en büyük ağacın üretilmesi.

4. En büyük ağaca budama yapılması ve en uygun ağacın elde edilmesi.

RA'larda hangi değişkenin en iyi bölünmeyi verdiğine karar vermeyi sağlayan bölme kriteri düğüm içi varyanstır. Bu bağlamda safsızlık ölçütü olan düğüm içi varyans, hata kareler toplamı alınarak hesaplanır (Ma, 2018). Hata kareler toplamı (Sum of Squares) şu şekilde formülize edilir (Therneau & Atkinson, 2023a):

$$SS_T = \sum (y_i - \bar{y})^2 \quad (1)$$

Denklem 1'de verilen y_i i bireyinin bağımlı değişkene ilişkin gözlenen değeri iken, \bar{y} bağımlı değişkene ilişkin düğüm ortalamasıdır. RA'larda bir üst düğüm bölündüğünde, üst düğümün safsızlık ölçüsü alt düğümlerinkine karşılaştırılır. Ana düğüm ve çocuk (alt) düğümler arasında safsızlıktaki en

büyük azalmayı veren bağımsız değişken bölme değişkeni olarak seçilir (Ma, 2018). Bu kriter ise şu şekildedir (Therneau & Atkinson, 2023a):

$$SS_T - (SS_L + SS_R) \quad (2)$$

Burada SS_L ve SS_R sırasıyla sol ve sağ çocuk düğümleri için kareler toplamıdır (Therneau & Atkinson, 2023a). Son adımdaki budama işlemi maliyet-karmaşıklık ölçütüyle büyük ağaca bir ceza terimi ekleme yoluyla yapılır (Ma, 2018). Burada olası tüm ağaçları dikkate almak yerine negatif olmayan bir ayar parametresi α ile indekslenen bir ağaç dizisi ele alınır. α 'nın her değeri için $T < T_0$ alt ağacı vardır (James ve diğerleri, 2013). Bu durumda, α (karmaşıklık parametresi), modele başka bir değişken eklemenin maliyetini ölçen 0 ile ∞ arasında bir sayıdır. Buna göre maliyet-karmaşıklık değeri şu şekildedir (Therneau & Atkinson, 2023a):

$$R_\alpha(T) = R(T) + \alpha|T| \quad (3)$$

Denklem 3'teki $|T|$ terminal düğümlerin (daha fazla bölünmeyen düğüm) sayısıdır. $R(T)$ ise hata kareler toplamıdır (Therneau & Atkinson, 2023a). Yukarıda verilen ağaç oluşturma sürecindeki dört adım tamamlandıktan sonra her bir terminal düğüme, bu düğümdeki bağımlı değişkene ilişkin sabit bir ortalama değer atanarak tahmin yapılır (Strobl, 2013).

Çalışmada dikkate alınan diğer yöntem olan çoklu doğrusal regresyon (ÇDR) analizinde de temel amaç RA'lar ile benzer şekilde, genellikle bir bağımlı değişken ile birden fazla bağımsız değişken arasındaki ilişkinin incelenmesidir (Tabachnick ve Fidell, 2013/2020). Bu tekniğin uygulanması için bağımlı ve bağımsız değişkenlerde uç değerlerin olmaması, artıkların normalliği, doğrusallığı, varyansların homojenliği, çoklu doğrusal bağlantı olmaması gibi varsayım ve koşulların karşılanması gerekir (Tabachnick ve Fidell, 2013/2020).

Alan yazın incelendiğinde regresyon teknikleriyle SRA'ların eğitim alanında karşılaştırıldığı bazı araştırmaların olduğu görülmektedir. Buna göre Sinharay (2016) tarafından yapılan çalışmada üç farklı veri setiyle karşılaştırmalar gerçekleştirilmiştir. İlk olarak maddelerin konu düzeyi, ilgili oldukları bilişsel alan ve okuma yükü özelliklerinden yararlanarak TIMSS 2007 4. Sınıf matematik değerlendirmesindeki verilere göre maddelerin eğitim ve güçlük parametrelerinin tahmin edilmesi amaçlanmıştır. Analizlerde ÇDR, RA, gradyan artırma ve rastgele orman yöntemlerinin performansları incelenmiştir. Sonuçta RA'nın ÇDR'den ciddi bir farklılık olmamakla birlikte, biraz daha iyi performans gösterdiği bulunmuştur. Aynı çalışmadaki ikinci analizde liseyi terk etme durumuna ilişkin kestirimler lojistik regresyon, çok düzeyli lojistik regresyon, sınıflandırma ağacı, gradyan artırma ve rastgele orman yöntemleriyle gerçekleştirilmiştir. Sonuçlara göre sınıflandırma ağacı lojistik regresyondan biraz daha iyi performans göstermiştir. Üçüncü analizde ise küçük ($n=100$) ve büyük ($n=620$) örneklemelerde bireylerin kompozisyon sınavındaki performanslarına ilişkin tahminler yapılmıştır. Doğrusal regresyon, kümülatif lojistik regresyon, sınıflandırma ağacı, gradyan artırma ve rastgele orman yöntemleri kullanılmıştır. Küçük veri setinde makine öğrenme yöntemlerinin geleneksel karşılıklarına göre sağladıkları iyileşmenin daha büyük olduğu vurgulanmıştır. Araştırmacı tüm analizleri birlikte değerlendirdiğinde, kullandığı makine öğrenme yöntemlerinin geleneksel karşılıklarına göre sağladığı iyileşmenin mütevazı boyutta olduğunu vurgulamıştır. Bu alanda yapılan bir başka çalışma Gomes ve diğerleri (2021) tarafından yürütülmüştür. Çalışmada 3.670.089 bireyin okuduğunu anlama performansı RA ve ÇDR analizleri ile tahmin edilmiştir. Araştırmacılar farklı ölçek türlerindeki büyük ve karmaşık veri setlerinde RA'nın sunduğu anlaşılır çözümlere ve yöntemin doğrusal olmayan ilişkileri ortaya çıkarabilmesine dikkat çekmiştir. Aksu ve Keceoglu (2019) tarafından yapılan araştırmada ise PISA 2012 matematik performansını etkileyen değişkenlerin incelenmesi kapsamında lojistik regresyon, CHAID (Chi-squared Automatic Interaction Detection) ve sınıflandırma ağacı algoritmalarından REPTree yöntemleri

karşılaştırılmıştır. Buna göre sınıflandırma doğruluğu açısından en iyi performansı lojistik regresyon göstermişken bunu CHAID ve REPTree takip etmiştir.

RA ve ÇDR analizlerinin kıyaslanmasına ilişkin farklı disiplinlere ait çalışmalar da bulunmaktadır. Özellikle ekoloji alanındaki araştırmaların yoğunluğu dikkat çekmiştir. Örneğin Pinheiro ve diğerlerinin (2018) çalışmasında üst toprak dokusunun tahmin edilmesi amaçlanmıştır. Tahmin işlemleri için ÇDR ve RA kullanılmıştır. Elde edilen sonuçlara göre iki yöntem de performans açısından benzer olmakla birlikte RA'nın daha iyi sonuçlar verdiği bulunmuştur. Yine bu alanda Mohammadi ve diğerlerinin (2011) çalışmasında RA, doğrusal regresyondan daha iyi performans sergilemiştir. Ploner & Brandenburg (2003) tarafından yapılan araştırmada ise doğrusal regresyon ve RA arasında, doğrusal regresyon için küçük avantajlarla birlikte karşılaştırılabilir tahmin gücüne dikkat çekilmiş ve RA'nın sağladığı basit görselleştirmenin önemine vurgu yapılmıştır. Kocarık Gacar ve Deveci Kocakoç (2020) tarafından yapılan bir başka çalışmada ise konut fiyatlarının tahmininde doğrusal regresyon, lojistik regresyon, RA ve sınıflandırma ağacı yöntemlerinin performansı karşılaştırılmıştır. Sonuçlara göre en iyi performansı sınıflandırma ağaçları göstermiştir. RA ve doğrusal regresyon karşılaştırmasına göre ise eğitim veri setinden yapılan tahmine göre RA, test veri setinden yapılan tahmine göre doğrusal regresyon daha iyi performans göstermiştir. Tıp alanında gerçekleştirilen Allore ve diğerlerinin (2005) çalışmasında ÇDR ve RA yöntemlerinin sosyal ve üretken faaliyetlere ilişkin tahmin performansı incelenmiştir. Buna göre eğitim verisinde her iki yöntem benzer uyum gösterirken, test verisinde RA daha iyi sonuçlar vermiştir.

RA ve ÇDR analizlerinin veri setinin özellikleri bağlamında incelendiği çeşitli araştırmalar da bulunmaktadır. Buna göre Kim (2008) RA, doğrusal regresyon ve yapay sinir ağı (YSA) yöntemlerinin bağımsız değişken sayısı, bağımsız değişken türü, bağımsız değişkenlerin kategori sayısı ve örneklem büyüklüğüne göre performanslarını simülatif bir çalışmada incelemiştir. Buna göre sürekli bağımsız değişkenler için doğrusal regresyon daha iyi performans göstermiştir. Aynı zamanda bu durum için örneklem büyüklüğü ve bağımsız değişken sayısı arttıkça hemen hemen tüm durumlarda doğrusal regresyon RA'dan daha iyi, YSA ile eşit ya da daha iyi performans sergilemiştir. Sürekli ve kategorik değişkenlerin varlığında doğrusal regresyon kategorik değişken sayısı bir ise en iyi, YSA kategorik değişken sayısı iki veya daha fazla ise en iyi performansı göstermiştir. Bu durumda örneklem küçük olduğunda doğrusal regresyon, büyük olduğunda YSA diğerlerine göre daha iyi performansa sahiptir. Son olarak kategorik değişkenlerin kategori sayısı arttıkça YSA'nın performansı diğer yöntemlere göre daha fazla iyileşmiştir. Ağaç tabanlı regresyon modelleri (RA ve rastgele orman) ve ÇDR'nin, veri setinin özellikleri dikkate alınarak karşılaştırıldığı bir başka çalışma Chowdhury ve diğerleri (2022) tarafından yapılmıştır. Araştırmacılar ticari lityum pillerinin bazı özelliklerinden pilin çevrim ömrünü tahmin etmişlerdir. Birbirleriyle 0,90 ve üzeri ilişki gösteren yordayıcılar kullanmışlardır. Çalışmada çoklu doğrusal bağlantıya sahip ve çarpık bir veri seti kullanılarak bu durumların performansa etkisi incelenmiştir. Elde edilen sonuçlara göre çalışmadaki veri setinin özelliklerini barındıran durumlarda ağaç tabanlı modellerin kullanımının daha iyi tahmin performansına yol açtığı bulunmuştur. Benzer kapsamda başka bir çalışma Piramuthu (2008) tarafından yapılmıştır. Araştırmacı veride doğrusal olmama, uç değer bulunması, varyansların homojen olmaması ve çoklu doğrusal bağlantının varlığının RA ve ÇDR analizlerinin performanslarına etkilerini incelemiştir. Elde edilen sonuçlara göre doğrusal olmama ve uç değer varlığı ağaç performansını olumsuz yönde etkilemiştir. Varyansların homojen olmaması performansı önemli ölçüde etkilemezken, çoklu doğrusal bağlantı varlığında ise ağaçların performansı olumsuz etkilenmemiştir. Ancak burada bahsedilen son iki çalışmada yalnızca tahmin performansı dikkate alınmıştır. Buna karşılık Piramuthu (2008) regresyon analizinde amaç tahmin ise çoklu bağlantının sorun olmayacağını ancak amacın katsayıların yorumlanması olduğunda bunun bir

sorun olacağını vurgulamıştır. Dolayısıyla yorum yaparken araştırmacının amacının ve veri setinin özelliklerinin belirleyici olacağı düşünülmektedir.

1.1. Matematik Okuryazarlığı

Matematik hayatta karşılaşılabilecek pek çok sorunun çözümünde kritik bir araçtır. PISA 2022'de ana değerlendirme alanı olan matematik okuryazarlığı 21. yüzyılda görülen iklim değişikliği, salgın hastalıkların yayılması, nüfus artışı vb. gibi değişen koşul ve sorunları anlamak ve ele alabilmek için gerekli bir beceridir. Öğrenciler bu becerinin önemli bir parçası olan matematiksel muhakemeyi kullanarak matematiksel düşünmeyi öğrendiklerinde 21. yüzyıldaki yaşamın niceliksel boyutlarını algılayabilecekleri bir kavramsal çerçeveye sahip olurlar. Böyle bir matematik anlayışına sahip olmak bir gencin modern topluma katılmasının ve katkıda bulunmasının temelinde yer alır (OECD, 2023a). Her bireyin değişen ölçülerde sahip olduğu ve geliştirilebilir bir özellik olan matematik okuryazarlığı PISA 2022'de şu şekilde tanımlanmıştır (OECD, 2023a, s.22):

“Matematik okuryazarlığı, bir bireyin matematiksel olarak akıl yürütme ve çeşitli gerçek dünya bağlamlarındaki problemleri çözmek için matematiği formüle etme, kullanma ve yorumlama kapasitesidir. Olguları tanımlamak, açıklamak ve tahmin etmek için kavramları, süreçleri, gerçekleri ve araçları içerir. Bireylerin matematiğin dünyada oynadığı rolü bilmelerine ve yapıcı, ilgili ve yansıtıcı 21. yüzyıl vatandaşlarının ihtiyaç duyduğu sağlam temelli yargı ve kararları vermelerine yardımcı olur.”

1.2. Araştırmanın Amacı ve Önemi

Regresyon ağaçları, çoklu doğrusal regresyon analizinin parametrik olmayan karşılığı olarak görülmektedir. Bu iki yöntemin karşılaştırılmasına ilişkin çalışmalar incelendiğinde sıklıkla farklı disiplinlere ait araştırmaların varlığı göze çarpmaktadır. Ancak veri setinin çeşitli özelliklerine göre birbirlerinin alternatifi olabilecek bu iki yöntemin eğitim alanında performansının karşılaştırılmasına ilişkin araştırmaların oldukça sınırlı olduğu görülmüştür. Her bir yöntemin avantaj ve sınırlılıkları bulunmaktadır. Yöntemin sağladığı avantaj ve uygunluk düzeyi araştırma sorusu, veri setinin yapısı vb. özelliklerine göre değişmektedir. Bu sebeple çalışmada eğitim alanından hem büyük gerçek bir veri setinde hem de bu veri setinden çekilen 200 farklı örnekleme RA ve ÇDR analizlerinin performanslarının karşılaştırılması amaçlanmıştır. Benzer amaçlara hizmet eden fakat kullanılmaları için gerekli koşulların farklılık gösterdiği RA ve ÇDR analizlerinin eğitsel bir veri setinde karşılaştırılmasıyla veri setinin özelliklerine göre yöntemlerin katkıları ve/veya sınırlılıkları hakkında çıkarımlar yapılmıştır. Bu sayede her iki yöntemin güçlü ve zayıf yönleri tartışılarak, araştırmacıların analiz yöntemine karar verme süreçlerini destekleyecek bulgularla alan yazına katkıda bulunması umulmaktadır. Buna göre araştırma soruları şu şekildedir:

1. RA ve ÇDR analizlerinin matematik okuryazarlığı becerisini yordama performansları veri setinin tamamı için nasıldır?
2. Her iki yöntem için matematik okuryazarlığı becerisinin yordanmasına katkıda bulunan değişkenlerin önem sıralaması nedir?
3. RA ve ÇDR analizlerinin matematik okuryazarlığı becerisini yordama performansları 200 farklı alt örnekleme nasıldır?

2. Yöntem

2.1. Araştırmanın Deseni

Araştırmada ÇDR analizi ve RA algoritmasının PISA 2022 matematik okuryazarlığını yordama performansları ve bu beceriyi yordayan önemli değişkenler incelenmiştir. Buna göre çalışma, değişkenleri etkilemeye yönelik herhangi bir işlem yapılmadan değişkenler arasındaki ilişkilerin incelenmesi bakımından ilişkisel araştırmadır (Fraenkel ve diğerleri, 2012).

2.2. Evren ve Örneklem

Çalışmanın evrenini PISA 2022 döngüsüne Türkiye'den katılan öğrenciler (n=7250) oluşturmaktadır. Bu değerlendirmede katılımcılar iki aşamalı tabakalı örnekleme yöntemiyle belirlenir. Buna göre ilk aşamada okullar sistematik örneklemeyle seçilir. İkinci aşamada katılımcı ülkenin/ekonominin bilgisayar tabanlı ya da kâğıt tabanlı değerlendirmeye katılma durumuna göre belirlenen hedef küme büyüklüğüne ulaşılacak biçimde öğrenciler seçilir. Bu aşamada belirlenen sayıda öğrenci rastgele örneklemeyle ya da hedef sayıdan daha az öğrenci olması halinde okuldaki öğrencilerin tamamının seçilmesi yoluyla belirlenir (OECD, 2024). İlk iki araştırma problemi için bu veri setinden eksik değerlerin liste bazında silinmesi, tek değişkenli ve çok değişkenli uç değerlerin incelenmesi sonucu 6645 (3293 kız, 3352 erkek) bireyin cevaplarını içeren örneklem üzerinde analizler gerçekleştirilmiştir. Üçüncü alt problem için ise her birinin büyüklüğü 1000 olacak şekilde esas veri setinden 200 farklı alt örneklem çekilmiştir.

2.3. Veri Toplama Araçları¹

Çalışmada PISA 2022'de yer alan çeşitli anket maddelerine verilen yanıtlar, öğrenci anketlerinden elde edilen indeksler ve bazı bilişsel alan puanları kullanılmıştır. Buna göre çalışmanın bağımlı değişkeni matematik okuryazarlığı becerisine ilişkin birinci olası değer olmuştur. Bağımsız değişkenler dijital kaynakların kullanımı ile ilgili iki anket maddesi, haftalık ders saati sayısı, matematik öz yeterliğine ilişkin iki farklı indeks, matematiksel kavramlara aşinalık, Bilgi ve İletişim Teknolojisi kaynakları, ev olanakları, ekonomik, sosyal ve kültürel statü indeksi, okuduğunu anlama becerisine ilişkin birinci olası değer olarak sıralanabilir. Bağımsız değişkenlerin belirlenmesinde, bağımlı değişkenle anlamlı ve/veya orta-yüksek korelasyona sahip olanlar ve çoklu bağlantıya sebep olmayanların seçilmesine yönelik bir yaklaşım benimsenmiştir. Değişkenlere ilişkin ayrıntılı açıklamalar Tablo 1'de verilmiştir (OECD, 2024).

¹ Çalışmada ikincil veriler kullanılmıştır. Bu sebeple etik kurul onayı gerekli değildir.

Tablo 1. Çalışmada Kullanılan Değişkenlere İlişkin Açıklamalar

Değişken Adı		Ölçek Türü	Açıklama
Anket Maddeleri		Sıralama	ST326Q05JA: Bu sene okuldan önce ve sonra boş zamanlarınızı değerlendirmek için dijital kaynakları günde kaç saat kullandınız?
			ST326Q06JA: Bu sene hafta sonları eğlence için dijital kaynakları günde kaç saat kullandınız?
			ST059Q02JA: Matematik de dahil olmak üzere haftalık ders saati sayısı kaçtır?
MATHEFF	Matematik öz yeterliği: Formal ve uygulamalı matematik	Sürekli	Okul müfredatlarında sıklıkla karşılaşılan temel ve bilindik matematiksel işlemleri uygulamayı gerektiren sorularda öğrencilerin kendilerine ne kadar güvendiklerine dair her biri dört kategorili dokuz sorudan oluşan ölçeğe göre hesaplanan değerdir.
MATHEFF21	Matematik öz yeterliği: Matematiksel muhakeme ve 21. yüzyıl matematiği	Sürekli	Matematiksel akıl yürütme gerektiren diyagramlardan, grafik veya simülasyonlardan matematiksel bilgi çıkarma, karar vermek için istatistiksel kavramları kullanma gibi 21. yüzyıl matematiği görevlerinde öğrencilerin kendilerine ne kadar güvendiklerine dair her biri dört kategorili on sorudan oluşan ölçeğe göre hesaplanan değerdir.
FAMCON	Matematik kavramlarına aşinalık	Sürekli	Bölen, üstel fonksiyon, üç boyutlu geometri vb. gibi farklı düzeylerdeki matematiksel kavramlara aşinalık düzeylerini ölçen her biri beş kategorili on maddeye göre hesaplanan değerdir.
ICTRES	Bilgi ve İletişim Teknolojisi (BİT) kaynakları	Sürekli	Öğrencilerin evlerinde bulunan çeşitli BİT kaynaklarının varlığına ilişkin maddeler içeren ölçeğe göre hesaplanan değerdir.
HOMEPOS	Ev olanakları	Sürekli	Öğrencilerin evlerinde sahip oldukları eşyalara ilişkin maddeler içeren ölçeğe göre hesaplanan değerdir.
ESCS	Ekonomik, sosyal ve kültürel statü indeksi	Sürekli	En yüksek ebeveyn meslek durumu, ebeveynlerin yıl olarak en yüksek eğitim düzeyi ve ev olanakları göstergelerine dayalı olarak hesaplanan değerdir.
PV1READ		Sürekli	Okuduğunu anlama puanına ilişkin 1. olası değerdir.
PV1MATH (Bağımlı değişken)		Sürekli	Matematik okuryazarlığı puanına ilişkin 1. olası değerdir.

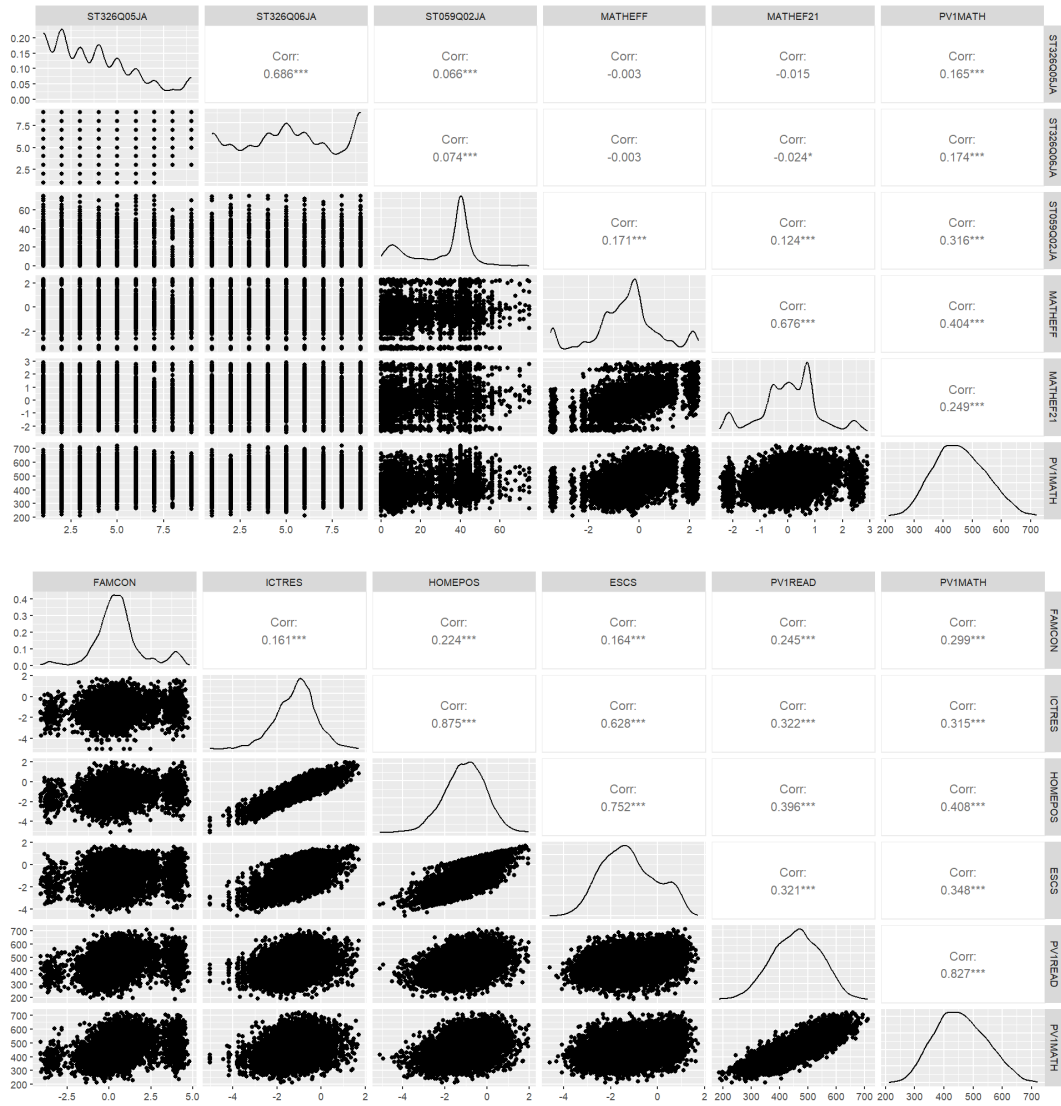
2.4. Verilerin Analizi

Çalışmada verinin incelemesi ve analizlerin gerçekleştirilmesinde R yazılımında (R Core Team, 2024) bulunan `expss` (Demin, 2023), `psych` (Revelle, 2024), `dplyr` (Wickham ve diğerleri, 2023), `GGally` (Schloerke ve diğerleri, 2024), `olsrr` (Hebbali, 2024), `knitr` (Xie, 2024), `tidyr` (Wickham ve diğerleri, 2024), `broom` (Robinson ve diğerleri, 2024), `QuantPsyc` (Fletcher, 2022), `caret` (Kuhn, 2008), `Metrics` (Hamner & Frasco, 2018), `rpart` (Therneau & Atkinson, 2023b) ve `rpart.plot` (Milborrow, 2024) paketleri kullanılmıştır. ÇDR analizi için varsayım kontrolü gerçekleştirilmiştir. Buna göre artıklara ilişkin grafikler incelenmiş ve normal dağılım gösterdikleri görülmüştür. Öte yandan çoklu bağlantının var olup olmadığının incelemesi için tolerans ve VIF (Variance Influence Factor) değerleri ile bağımsız değişkenler arasındaki korelasyon değerleri incelenmiştir. Çoklu bağlantı problemi olmaması için basit ikili korelasyon değerlerinin 0,90 ve üzerinde olmaması (Tabachnick ve Fidell, 2013/2020), VIF değerlerinin düşük, tolerans değerlerinin yüksek olması gerekmektedir (Howell, 2013/2019). Tolerans değeri 0 ile 1 arasında değişir ve sıfıra yakın değerler çoklu bağlantıya işaret etmektedir (Mertler & Vannatta, 2017). Öte yandan VIF değerinin 10'dan büyük olması çoklu doğrusal bağlantı sorununa işaret eder (Stevens, 2009). Çalışmada değişkenler arasındaki basit ikili korelasyon değerleri -0,024 ile 0,875, tolerans değerleri 0,157 ile 0,891, VIF değerleri 1,270 ile 6,371 arasında değişmiştir. Dolayısıyla veri setinde çoklu doğrusal bağlantı sorunu olmadığı görülmüştür. RA analizlerinde ise en uygun eğitim ve test verisi büyüklüklerine karar vermek için %50-%50, %60-%40, %70-%30 ve %80-%20 eğitim-test büyüklüğüne göre ayrı ayrı RA modelleri kurulmuştur. Metrik değerlerine göre en iyi sonuç %70-%30 koşulu için oluşmuştur. Bu sebeple yalnızca %70 eğitim verisi, %30 test verisine göre yapılan RA analizinin sonucu raporlanmıştır. Yöntemlerin performanslarının karşılaştırılması için MAE (ortalama mutlak hata), MAPE (ortalama mutlak hata yüzdesi), MSE (hata kareler ortalaması), RMSE (hata kareler ortalamasının kökü), yanlışlık, beklenen ve gözlenen değerler arasındaki korelasyon ve açıklanan varyans metrikleri kullanılmıştır. Aynı zamanda esas veri setinden her bir yöntem için büyüklüğü 1000 olacak şekilde 200 alt örneklem oluşturulmuştur. Bu aşamada öncelikle her bir metrik değerine göre yöntemlerin alt örneklemelerin kaçında daha iyi performans sergilediği incelenmiştir. Ardından alt örneklemelerin tamamına göre ortalaması alınan metrik değerleri karşılaştırılmıştır.

3. Bulgular

Bu bölümde ÇDR ve RA yöntemlerinden elde edilen sonuçlara yer verilmiştir. Bahsedilen bulgulara geçmeden önce değişkenlerin dağılımları, birbirleriyle ilişkilerine yönelik değerler ve grafikler bulguların yorumlanmasında göz önünde bulundurulduğu için Şekil 1'de verilmiştir.

Şekil 1. Değişkenler Arasındaki İlişkiler



Şekil 1’de sol alt köşegende değişkenler arasındaki ilişkileri gösteren saçılım grafikleri bulunmaktadır. Ana köşegendeki eğriler her bir değişkenin dağılımını gösterir. Şeklin sağ üst köşegenindeki değerler ise değişkenler arasındaki korelasyon değerleridir. Tüm değişkenlerin bağımlı değişkenle olan korelasyon katsayıları istatistiksel olarak anlamlıdır. Bağımlı değişkenle en yüksek korelasyona sahip değişkenin okuduğunu anlama puanı olduğu görülmektedir. Ek olarak bağımsız değişkenlerin kendi aralarında ve bağımlı değişkenle aralarında doğrusal ilişkiler olduğu ifade edilebilir.

3.1. Çoklu Doğrusal Regresyon Analizine İlişkin Bulgular

Bu analize ilişkin sonuçlar Tablo 2’de verilmiştir.

Tablo 2. Çoklu Doğrusal Regresyon Analizi Sonuçları

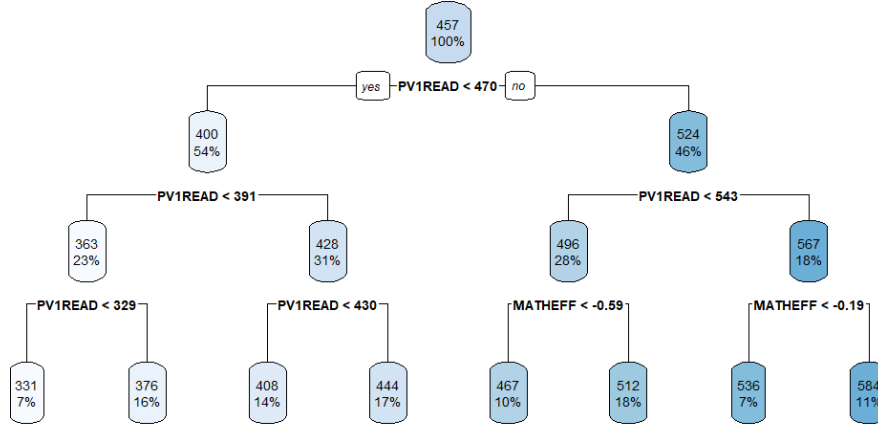
	Katsayı	Standart Hata	β	p	F değeri	p
Kesişim	111,698	4,010	-	0,000*	1744	0,000*
ST326Q05JA	0,417	0,337	0,011	0,215	656,81	0,000*
ST326Q06JA	-0,282	0,296	-0,009	0,340	166,72	0,000*
ST059Q02JA	0,266	0,037	0,048	0,000*	2208,63	0,000*
MATHEF	9,941	0,655	0,140	0,000*	3080,69	0,000*
MATHEF21	1,785	0,736	0,022	0,015*	23,17	0,000*
FAMCON	1,957	0,451	0,031	0,000*	420,36	0,000*
ICTRES	-6,225	1,311	-0,064	0,000*	846,44	0,000*
HOMEPOS	8,392	1,485	0,092	0,000*	841,66	0,000*
ESCS	3,849	0,749	0,051	0,000*	75,06	0,000*
PV1READ	0,754	0,008	0,729	0,000*	9117,12	0,000*

Tablo 2’ye göre tüm katsayıların F değerlerinin anlamlı çıktığı görülmektedir. Yani regresyon modelinin veriye iyi uyum sağladığı söylenebilir. Anlamlı çıkan değişkenler önem sıralamasına göre PV1READ (okuduğunu anlama), MATHEFF (formal ve uygulamalı matematiğe yönelik öz yeterlik), HOMEPOS (ev olanakları), ICTRES (BİT kaynakları), ESCS (Ekonomik, sosyal ve kültürel statü indeksi), ST059Q02JA (haftalık ders saati sayısı), FAMCON (matematiksel kavramlara aşinalık), MATHEFF21 (matematiksel muhakeme ve 21. yüzyıl matematiğine yönelik öz yeterlik) olmuştur. Katsayılar yorumlanacak olursa, diğer değişkenlerin etkileri kontrol altına alındıktan sonra; okuduğunu anlama puanındaki bir birimlik artışın matematik okuryazarlığındaki performansı 0,754 birim artırmaya, formal ve uygulamalı matematiğe yönelik öz yeterlik düzeyindeki bir birimlik artışın matematik okuryazarlığındaki performansı 9,941 birim artırmaya, ev olanakları değişkenindeki bir birimlik artışın matematik okuryazarlığındaki performansı 8,392 birim artırmaya, BİT kaynaklarına sahip olma düzeyindeki bir birimlik artışın matematik okuryazarlığındaki performansı 6,225 birim azaltmaya, ekonomik/sosyal ve kültürel statüdeki bir birimlik artışın matematik okuryazarlığındaki performansı 3,849 birim artırmaya, okuldaki haftalık ders saatindeki bir birimlik artışın matematik okuryazarlığındaki performansı 0,266 birim artırmaya, matematiksel kavramlara aşinalık düzeyindeki bir birimlik artışın matematik okuryazarlığındaki performansı 1,957 birim artırmaya, matematiksel muhakeme ve 21. Yüzyıl matematiğine yönelik öz yeterlik düzeyindeki bir birimlik artışın matematik okuryazarlığındaki performansı 1,785 birim artırmaya eğilimli olduğu görülmektedir.


3.2. Regresyon Ağacı Analizine İlişkin Bulgular

Bu analize ilişkin elde edilen regresyon ağacı Şekil 2’de verilmiştir.

Şekil 2. Regresyon Ağacı



Şekil 2’de verilen regresyon ağacı incelendiğinde ilk bölünmenin okuduğunu anlama puanına göre gerçekleştiği görülmektedir. Şekildeki mavi kutucuklardaki üstte yazan değer, bu bölünmede bulunan bireylerin matematik okuryazarlığı puanı ortalamasıdır. Altta yazan değer ise buradaki kişilerin örneklem içindeki yüzdesidir. Her bir bölünmede eğer değişkene ilişkin koşul sağlanıyorsa gözlemler sola, sağlanmıyorsa sağa gönderilir. Buna göre örneğin, ağacın en solundaki bölünmeler takip edilecek olursa sırasıyla okuduğunu anlama puanı 470’den, 391’den ve 329’dan küçük olanların matematik okuryazarlığı puanının en düşük olma eğiliminde olduğu (ortalama 331 puan) görülmektedir. Regresyon ağaçlarında farklı bölünmelerde aynı değişkenin kullanılması safsızlığı daha çok azaltan değişkenlerin seçilme yaklaşımından dolayı gerçekleşmektedir. Öte yandan ağacın en sağ tarafındaki bölünmeler incelenecek olursa okuduğunu anlama puanı sırasıyla 470’den ve 543’ten büyük ve eşit olanların, formal ve uygulamalı matematikteki öz yeterlik puanı $-0,19$ ’dan büyük ve eşit olanların en yüksek puanı alma (ortalama 584 puan) eğiliminde oldukları söylenebilir. Regresyon ağacı analizine göre değişkenlerin önem sıralaması Şekil 3’te verilmiştir.

Şekil 3. Regresyon Ağacına Göre Değişken Önemi Sıralaması

Şekil 3'e göre matematik okuryazarlığını en fazla etkileyen değişkenin baskın bir şekilde okuduğunu anlama puanı olduğu görülmektedir. Tablo 3'te yöntemlere ilişkin metrik değerleri yer almaktadır.

Tablo 3. Yöntemlere İlişkin Metrik Değerleri

	MAE	MAPE	BIAS	MSE	RMSE	R	R ²
ÇDR	36,616	0,083	0,000	2110,620	45,941	0,851	0,724
RA	39,393	0,090	-0,489	2453,938	49,537	0,820	0,672

Tablo 3 incelendiğinde her iki modelin veriye uyum düzeylerinin iyi olduğu söylenebilir. Bununla birlikte tüm metrik değerlerine göre ÇDR'nin daha iyi tahmin performansı sergilediği görülmektedir.

3.3. Tekrarlı Analizlere İlişkin Bulgular

200 farklı alt örneklemden elde edilen sonuçlar dikkate alındığında ÇDR; MAE ve yanlılık metriklerine göre tüm alt örneklemlerde, MAPE, korelasyon ve açıklanan varyansa göre 199 alt örneklemden, MSE ve RMSE metriklerine göre 198 alt örneklemden daha iyi performans sergilemiştir. Alt örneklemlerin tamamına göre ortalaması alınan metrik değerlerine ilişkin sonuçlar Tablo 4'te verilmiştir.

Tablo 4. Tekrarlı Analizlere İlişkin Ortalama Metrik Değerleri

	MAE	MAPE	BIAS	MSE	RMSE	R	R ²
ÇDR	36,504	0,083	0,000	2094,951	45,759	0,851	0,725
RA	40,714	0,092	-0,215	2623,104	51,169	0,810	0,653

Tablo 4 incelendiğinde her iki modelin veri setinin tamamının ele alındığı sonuçlara benzer şekilde veriye uyum düzeylerinin iyi olduğu ve tüm metrik değerlerine göre ÇDR'nin daha iyi tahmin performansı sergilediği söylenebilir.

4. Sonuç, Tartışma ve Öneriler

Çalışmada ÇDR ve RA analizlerinin matematik okuryazarlığını yordama performansları ve bağımsız değişkenlerin önem sıralamaları incelenmiştir. Öncelikle, tüm veri seti dikkate alınarak gerçekleştirilen analizden elde edilen metrik değerlerine göre her iki yöntemin de iyi performans sergilediği görülmüştür. Bununla birlikte ÇDR'nin daha iyi metrik değerlerine sahip olduğu söylenmelidir. Buna ek olarak hem tüm metriklere göre 200 alt örneklemin neredeyse tamamında hem de ortalaması alınmış tüm metrik değerlerine göre ÇDR'nin daha iyi performans sergilediği görülmüştür. Alan yazında bu konuda çeşitli bulgular raporlanmıştır. Allore ve diğerleri (2005) eğitim setinde bu iki yöntemin benzer, test setinde RA'nın daha iyi performans sergilediğini bulmuşlardır. Mohammadi ve diğerleri de benzer şekilde RA'nın daha iyi sonuç verdiğini raporlamışlardır. Tekniklerin performanslarının veriye bağlı olması sebebiyle etkinliklerini karşılaştırmak ve en iyisini belirlemek zordur (Kim, 2008). Dolayısıyla çalışmada elde edilen sonucun olası sebepleri incelenecek olursa; çalışmada kullanılan veri seti parametrik bir teknik olan ÇDR'nin varsayım ve gerekliliklerini karşılayacak biçimde düzenlenmiştir. Şekil 1 incelendiğinde değişkenler arasında orta ve güçlü doğrusal ilişkiler göze çarpmaktadır. Breiman ve diğerleri (1984) doğrusal ilişki içermeyen durumlarda RA'nın performansının doğrusal regresyona göre çok daha iyi olabileceğini, değişkenler arasında güçlü doğrusal ilişkiler varsa RA'nın performansının biraz daha düşük olma eğiliminde olduğunu ifade etmişlerdir. Eğer değişkenler arasında doğrusal olmayan ve karmaşık bir ilişki varsa, karar ağaçları klasik yaklaşımlardan daha iyi performans gösterebilir (James ve diğerleri, 2013). Bu durumda elde edilen performans farklılığının belli bir ölçüde veri setinin özelliklerinden kaynaklı olabileceği düşünülmektedir. Bununla birlikte veri seti ÇDR'nin gerekliliklerini karşıladığı için ÇDR lehine performans farklılığı olduğuna dair doğrudan bir ilişki kurmak da yanıltıcı olabilir. Chowdhury ve diğerleri (2022) tarafından yapılan çalışmada çoklu doğrusal bağlantıya ve çarpık dağılıma sahip bir veri setiyle yapılan karşılaştırmalar sonucu ağaç tabanlı modellerin ÇDR'ye göre daha iyi performans sergilediği raporlanmıştır. Öte yandan Piramuthu'nun (2008) elde ettiği bir dizi bulguya göre doğrusal olmayan ilişkilerin ve uç değerlerin varlığında ağaç performansı olumsuz etkilenmiştir. Varyansların homojen olmaması ise önemli bir etkiye sahip değilken çoklu doğrusal bağlantı varlığında ağaçların performansı olumsuz etkilenmemiştir. Ancak bahsedilen çalışmalarda yalnızca tahmin performansı incelenmiştir. Bununla birlikte Piramuthu (2008) regresyon analizinde sadece tahmin yapmak hedefleniyorsa çoklu bağlantının sorun oluşturmayacağını ancak katsayıların yorumlanması ve buna bağlı olarak değişkenlerin önem düzeyleriyle ilgili çıkarımlar yapılması durumlarında bunun bir sorun olacağını ifade etmiştir. Aynı zamanda Kim (2008) çalışmasında sürekli bağımsız değişkenlerin varlığında doğrusal regresyonun çalışmasında kullandığı RA ve YSA algoritmalarından daha iyi performans sergilediğini raporlamıştır. Eldeki çalışmada ise değişkenlerin üç tanesi sıralama, yedi tanesi sürekli ölçek türündedir. Dolayısıyla ÇDR'nin öne çıkan performansının sürekli değişkenlerin daha fazla olmasıyla da ilişkili olabileceği düşünülmektedir. Ancak Kim (2008) çalışmasında sürekli ve kategorik değişkenlerin varlığında yöntemlerin davranışını incelemiş, sıralama türündeki ölçeklere dair bir deney yapmamıştır. Bu bağlamda, yorum yaparken araştırmacının amacının ve veri setinin özelliklerinin belirleyici olacağı düşünülmektedir. Sonuç olarak, alan yazında veri setinin özelliklerine göre yöntemlerin davranışıyla ilgili daha genellenebilir çıkarımlar yapılmasını sağlayacak kapsamda çalışmaların artırılmasının faydalı olacağı düşünülmektedir. Öte yandan performansının iyi düzeyde olduğu görülen RA'da ÇDR'deki gibi bazı varsayım ve gerekliliklerin söz konusu olmayışı, büyük, çok miktarda yordayıcı içeren karmaşık veri setlerinde RA'ların tercih edilebilir bir alternatif olduğunu göstermektedir. Aynı zamanda RA değişkenler arasındaki ilişkiler için daha kolay yorumlanabilir ve anlaşılabilir bir ağaç yapısı sunmuştur. Değişkenlerin birlikte etkilerinin görülmesini sağlayan bu tür ilişkilerin çoklu regresyonda elde edilmesi için önceden ilişkilerin bilinerek

modele etkileşim terimlerinin eklenmesi gerekir. Ancak bu her zaman mümkün olmayabilir. SRA'larda ise geleneksel istatistiksel tekniklerde olduğu gibi bağımsız değişkenler arasındaki karmaşık etkileşimlerin önceden belirlenmesine gerek yoktur. Bu sayede olası yanlış belirleme sorunlarının önüne geçilerek geleneksel tekniklerin kolaylıkla başa çıkamadığı karmaşık ve doğrusal olmayan ilişkiler tespit edilebilir (Ma, 2018; Strobl ve diğerleri, 2009). RA'ların kesme noktası sunmasının ve etkileşimlerin önceden belirlenmesine gerek kalmadan buna ilişkin bilgi vermesinin (Allore ve diğerleri, 2005), sunduğu basit görselleştirmenin (Ploner & Brandenburg, 2003) çalışmalarına kattığı zenginlik çeşitli araştırmacılar tarafından vurgulanmıştır.

Çalışmanın ikinci alt problemine göre her iki yöntemde önemli değişkenlerin sıralamalarının neredeyse aynı olduğu görülmüştür. En önemli değişken olan okuduğunu anlamanın matematik performansı ile ilişkisini inceleyen bazı çalışmalar bulunmaktadır. Örneğin Güre ve diğerlerinin (2020) çalışmada matematik okuryazarlığını etkileyen önemli değişkenler arasında Türkçe başarı düzeyi olduğu bulunmuştur. Öztıp ve Toptaş (2022) tarafından gerçekleştirilen meta analiz çalışmada ise yıllara ve öğrenim kademelerine (ilkokul ve ortaokul) göre değişmeyecek biçimde matematik okuryazarlığı ile okuduğunu anlama arasında aynı şekilde pozitif yüksek düzeyde ilişki olduğu raporlanmıştır. Dolayısıyla okuduğunu daha iyi anlayan öğrencilerin matematiksel işlem ve kavramları daha iyi anlamlandırabildikleri ve bunun da performansa olumlu katkısı olduğu söylenebilir. İkinci sırada önemli bulunan formal ve uygulamalı matematiğe yönelik öz yeterlik (MATHEFF) ile ilgili pek çok çalışmada bu özellik düzeyinin matematik performansı ile pozitif ve/veya anlamlı ilişkide olduğu bulunmuştur (Aksu ve diğerleri, 2017; Aksu ve Güzeller, 2016; Aksu ve Keceoglu, 2019; Kesici, 2018; Okatan ve Tomul, 2020; Özkal, 2020; Şahin ve Yıldırım, 2016). Kendine ait bir odanın varlığı, eğitim yazılımı veya uygulamalarına sahip olma gibi maddeleri içeren ev olanakları değişkeni için de benzer şekilde matematik performansını olumlu yönde etkilediğine dair araştırmalar bulunmaktadır (Acar Güvendir, 2017; Karabay ve diğerleri, 2015). Dolayısıyla evdeki imkanların fazla olmasının erişilebilirliği ve konforu artırması sebebiyle performansa olumlu yansıdığı düşünülmektedir. Önemli bulunan bir diğer değişken Bilgi ve İletişim Teknolojilerine erişim olmuştur. Bu değişkenin etkisinin ÇDR analizine göre negatif yönde olduğu bulunmuştur. Bu durumun BİT kaynaklarının kullanım biçiminin değişim göstermesiyle ve sıklıkla eğitim amacıyla kullanılmamasıyla ilişkili olabileceği düşünülmektedir. Ekonomik, sosyal ve kültürel durumun ise matematik performansı ile önemli ve/veya pozitif ilişkili olduğuna dair çeşitli çalışmalar bulunmaktadır (Aksu ve diğerleri, 2020; Koğar, 2015; Guo, 2014; Okatan ve Tomul, 2020; Ötken, 2019). Sosyo-ekonomik düzeyin yüksekliği ailelerin çocuklarının eğitime katkıda bulunacak pek çok destek ve imkânı sunmasına yol açar. Ancak sosyo-ekonomik düzey ve performans arasındaki ilişkinin güçlü olması aynı zamanda daha az adil bir sistem anlamına da gelir (OECD, 2023b). Matematik performansı ve sosyo-ekonomik düzey arasındaki önemli ve pozitif ilişkinin azaltılması için toplumsal ve eğitimsel adaletsizliği giderecek önlemlerin alınması gerektiği söylenebilir. Diğer önemli bulunan değişken haftalık ders saati sayısıdır. Matematik okuryazarlığı ile pozitif ilişkili bu değişkenin etkisine göre matematik de dahil ders saati sayısının artmasının performansa olumlu yansıdığı söylenebilir. Öte yandan bu çalışmadakine benzer olarak matematik performansı ve matematiksel kavramlara aşinalık arasında da pozitif ilişki olduğu başka çalışmalarda da doğrulanmıştır (Arıkan, 2016). Son olarak matematiksel muhakeme ve 21. yüzyıl matematiğine yönelik öz yeterlik (MATHEFF21) düzeyi ile matematik okuryazarlığı arasında pozitif ilişki bulunmuştur. Bunlara ek olarak alan yazındaki PISA uygulamalarına ilişkin Türkiye'nin performansının incelendiği çalışmalara dair Sarier'in (2021) nitel incelemesine göre bahsedilen kapsamda yapılmış çalışmaların ortak bulguları olarak matematik, okuduğunu anlama ve fen başarısını yordayan önemli değişkenler arasında ev olanakları, ekonomik, sosyal ve kültürel statü ve özyeterlik olduğu raporlanmıştır.

Sonuç olarak çalışmada kullanılan her iki modelin bu veri seti için iyi düzeyde uyum gösterdiği görülmüştür. Buna ek olarak iki yöntemin de önemli değişkenler açısından uyumlu sonuçlar vermesi dikkat çekmiştir. Elde edilen sonuçlar veri setinin yapısı ve yöntemlerin özellikleri bağlamında tartışılmıştır. Araştırmacıların bu durumları dikkate alarak analiz yöntemine karar vermesi önerilmektedir.

Çalışmanın bazı sınırlılıkları bulunmaktadır. Buna göre araştırmada yalnızca iki yöntem sürekli ve sıralı bağımsız değişkenler bağlamında karşılaştırılmıştır. Aynı zamanda bağımlı değişken olarak matematik okuryazarlığına ilişkin birinci olası değer kullanılmıştır. Daha sonraki araştırmalarda farklı ölçek türlerindeki bağımsız değişkenler kullanılabilir. Aynı zamanda yöntemlerin daha büyük ve/veya daha küçük veri setlerindeki performansı incelenebilir. Ayrıca çoklu bağlantı ve veri setinin doğrusallık, normallik vb. özelliklerine dayalı yapılmış, yukarıda açıklanan araştırmaların az sayıda yordayıcı ve örneklem büyüklüğüne dayandığı görülmüştür. Dolayısıyla ileriki araştırmalarda daha fazla yordayıcı içeren daha büyük ve çeşitli dağılım özelliklerine sahip veri setleriyle yöntemlerin performansları incelenerek daha genellenebilir bulgular elde edilmesine yönelik çalışmalar yapılabilir. Aynı zamanda RA'ların bazı sınırlılıklarına çözüm sunan topluluk öğrenme yöntemleri ve/veya koşullu çıkarım ağaçlarına dayalı yöntemler gibi diğer makine öğrenme algoritmalarıyla karşılaştırmalar yapılabilir.

Kaynaklar

- Acar Güvendir, M. (2017). Determination of the relationship between students' mathematical literacy and home and school educational resources in the Program for International Student Assessment (PISA 2012). *Mersin University Journal of the Faculty of Education*, 13(1), 94–109. <https://doi.org/10.17860/mersinefd.305762>
- Aksu, G., & Güzeller, C. (2016). Classification of PISA 2012 mathematical literacy scores using decision-tree method: Turkey sampling. *Eğitim ve Bilim - Education and Science*, 41(185), 101–122. <https://doi.org/10.15390/EB.2016.4766>
- Aksu, G., & Keceoğlu, C. R. (2019). Comparison of results obtained from logistic regression, CHAID analysis, and decision tree methods. *Eurasian Journal of Educational Research*, 19(84), 115–134. <https://doi.org/10.14689/ejer.2019.84.6>
- Aksu, G., Güzeller, C. O., & Eser, M. T. (2017). Analysis of maths literacy performances of students with hierarchical linear modeling (HLM): The case of PISA 2012 Turkey. *Education & Science*, 42(191), 247–266. <https://doi.org/10.15390/EB.2017.6956>
- Aksu, N., Aksu, G., & Saraçalıoğlu, S. (2022). Prediction of the factors affecting PISA mathematics literacy of students from different countries by using data mining methods. *International Electronic Journal of Elementary Education*, 14(5), 613–629. <https://doi.org/10.26822/iejee.2022.267>
- Allore, H., Tinetti, M. E., Araujo, K. L., Hardy, S., & Peduzzi, P. (2005). A case study found that a regression tree outperformed multiple linear regression in predicting the relationship between impairments and social and productive activities scores. *Journal of Clinical Epidemiology*, 58(2), 154–161. <https://doi.org/10.1016/j.jclinepi.2004.09.001>
- Arıkan, S. (2016). Türkiye'deki öğrencilerin öğrenme fırsatları ve matematik performansları arasındaki ilişki. *Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 13(36), 47–66.
- Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Classification and regression trees*. CRC Press.
- Chowdhury, S., Lin, Y., Liaw, B., & Kerby, L. (2022, September). Evaluation of tree-based regression over multiple linear regression for non-normally distributed data in battery performance. In *2022 International Conference on Intelligent Data Science Technologies and Applications (IDSTA)* (pp. 17–25). IEEE. <https://doi.org/10.48550/arXiv.2111.02513>
- Demin, G. (2023). *exps: Tables, labels and some useful functions from spreadsheets and 'SPSS' statistics* (R package version 0.11.6). <https://CRAN.R-project.org/package=exps>
- Fletcher, T. D. (2022). *QuantPsyc: Quantitative psychology tools* (R package version 1.6). <https://CRAN.R-project.org/package=QuantPsyc>
- Fraenkel, J. R., Wallen, N. E., & Hyun, H. H. (2012). *How to design and evaluate research in education*. McGraw Hill.
- Gomes, C. M. A., Lemos, G. C., & Jelihovschi, E. G. (2021). The reasons why the regression tree method is more suitable than general linear model to analyze complex educational datasets. *Revista Portuguesa de Educação*, 34(2), 42–63. <https://doi.org/10.21814/rpe.18044>
- Guo, Y. (2014). Cross-cultural comparison of the school factors affecting students' achievement in mathematical literacy: Based on the multilevel analysis of PISA 2012. *China Examinations*, 10.

- Güre, Ö. B., Kayri, M., & Erdoğan, F. (2020). Analysis of factors affecting PISA 2015 mathematics literacy via educational data mining. *Education and Science / Eğitim ve Bilim*, 45(202), 393–415. <https://doi.org/10.15390/EB.2020.8477>
- Hamner, B., & Frasco, M. (2018). *Metrics: Evaluation metrics for machine learning* (R package version 0.1.4). <https://CRAN.R-project.org/package=Metrics>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction*. Springer.
- Hebbali, A. (2024). *olsrr: Tools for building OLS regression models* (R package version 0.6.0). <https://CRAN.R-project.org/package=olsrr>
- Howell, D. C. (2019). *Psikoloji için istatistiksel metotlar* (Y. Baykul, Çev. Ed.). Pegem Akademi Yayıncılık. (Eserin orijinali 2013'te yayınlandı).
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning with applications in R*. Springer.
- Karabay, E., Yıldırım, A., & Güler, G. (2015). Yıllara göre PISA matematik okuryazarlığının öğrenci ve okul özellikleri ile ilişkisinin aşamalı doğrusal modeller ile analizi. *Mehmet Akif Ersoy Üniversitesi Eğitim Fakültesi Dergisi*, 1(36), 137–151.
- Kesici, A. (2018). Lise öğrencilerinin matematik motivasyonunun matematik başarısına etkisinin incelenmesi. *Ondokuz Mayıs University Journal of Education Faculty*, 37(2), 177–194. <https://doi.org/10.7822/omuefd.438550>
- Kim, Y. S. (2008). Comparison of the decision tree, artificial neural network, and linear regression methods based on the number and types of independent variables and sample size. *Expert Systems with Applications*, 34(2), 1227–1234. <https://doi.org/10.1016/j.eswa.2006.12.017>
- Kocarık Gacar, B., & Deveci Kocakoç, İ. (2020). Regression analyses or decision trees? *Celal Bayar University Journal of Social Sciences / Celal Bayar Üniversitesi Sosyal Bilimler Dergisi*, 18(4), 251–260. <https://doi.org/10.18026/cbayarsos.796172>
- Koğar, H. (2015). Examination of factors affecting PISA 2012 mathematical literacy through mediation model. *Eğitim ve Bilim / Education and Science*, 40(179), 45–55. <https://doi.org/10.15390/EB.2015.4445>
- Kuhn, M. (2008). Building predictive models in R using the caret package. *Journal of Statistical Software*, 28(5), 1–26. <https://doi.org/10.18637/jss.v028.i05>
- Ma, X. (2018). *Using classification and regression trees: A practical primer*. IAP.
- Mertler, C. A., & Vannatta, R. (2017). *Advanced and multivariate statistical methods: Practical application and interpretation*. Routledge.
- Milborrow, S. (2024). *rpart.plot: Plot 'rpart' models: An enhanced version of 'plot.rpart'* (R package version 3.1.2). <https://CRAN.R-project.org/package=rpart.plot>
- Mohammadi, J., Shataee, S., & Babanezhad, M. (2011). Estimation of forest stand volume, tree density, and biodiversity using Landsat ETM+ data: Comparison of linear and regression tree analyses. *Procedia Environmental Sciences*, 7, 299–304. <https://doi.org/10.1016/j.proenv.2011.07.052>

- OECD. (2023a). *PISA 2022 assessment and analytical framework* (PISA). OECD Publishing. <https://doi.org/10.1787/dfc0bf9c-en>
- OECD. (2023b). *PISA 2022 results (Volume I): The state of learning and equity in education* (PISA). OECD Publishing. <https://doi.org/10.1787/53f23881-en>
- OECD. (2024). *PISA 2022 technical report* (PISA). OECD Publishing. <https://doi.org/10.1787/01820d6d-en>
- Okatan, Ö., & Tomul, E. (2021). Uluslararası Öğrenci Başarılarını Değerlendirme Programı'na (PISA) göre Türkiye'deki öğrencilerin matematik başarıları ile ilişkili değişkenlerin incelenmesi. *Mehmet Akif Ersoy Üniversitesi Eğitim Fakültesi Dergisi*, (57), 98–125. <https://doi.org/10.21764/maeuefd.663150>
- Ötken, Ş. (2019). *PISA uygulamalarında okuma-matematik-fen okuryazarlığı puanlarındaki değişimin çok değişkenli-çok düzeyli model ile incelenmesi* (Yayımlanmamış doktora tezi). Hacettepe Üniversitesi.
- Özkal, N. (2020). Öğretmen güdüsel desteği, özyeterlik inancı ve akademik başarı arasındaki ilişkiler: Lise matematik dersi örneği. *Akdeniz Üniversitesi Eğitim Fakültesi Dergisi*, 3(2), 88–97.
- Öztop, F., & Toptaş, V. (2022). Matematik başarıları ile okuduğunu anlama becerisi arasındaki ilişki: Bir meta-analiz çalışması. *Yıldız Journal of Educational Research*, 7(1), 12–21. <https://doi.org/10.14744/yjer.2022.002>
- Pinheiro, H. S. K., Carvalho, W. D., Chagas, C. D. S., Anjos, L. H. C. D., & Owens, P. R. (2018). Prediction of topsoil texture through regression trees and multiple linear regressions. *Revista Brasileira de Ciência do Solo*, 42, e0170167. <https://doi.org/10.1590/18069657rbcs20170167>
- Piramuthu, S. (2008). Input data for decision trees. *Expert Systems with Applications*, 34(2), 1220–1226. <https://doi.org/10.1016/j.eswa.2006.12.030>
- Ploner, A., & Brandenburg, C. (2003). Modelling visitor attendance levels subject to day of the week and weather: A comparison between linear regression models and regression trees. *Journal for Nature Conservation*, 11(4), 297–308. <https://doi.org/10.1078/1617-1381-00061>
- R Core Team. (2024). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing. <https://www.R-project.org/>
- Redelmeier, A., Jullum, M., & Aas, K. (2020). Explaining predictive models with mixed features using Shapley values and conditional inference trees. In A. Holzinger, P. Kieseberg, A. Tjoa, & E. Weippl (Eds.), *Machine learning and knowledge extraction: 4th IFIP TC 5, TC 12, WG 8.4, WG 8.9, WG 12.9 International Cross-Domain Conference, CD-MAKE 2020, Dublin, Ireland, August 25–28, 2020, Proceedings 4* (pp. 117–137). Springer International Publishing. https://doi.org/10.1007/978-3-030-57321-8_7
- Revelle, W. (2024). *psych: Procedures for psychological, psychometric, and personality research* (R package version 2.4.3). Northwestern University. <https://CRAN.R-project.org/package=psych>
- Robinson, D., Hayes, A., & Couch, S. (2023). *broom: Convert statistical objects into tidy tibbles* (R package version 1.0.5). <https://CRAN.R-project.org/package=broom>

- Romero, C., & Ventura, S. (2010). Educational data mining: A review of the state of the art. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 40(6), 601–618. <https://doi.org/10.1109/TSMCC.2010.2053532>
- Sarıer, Y. (2021). PISA uygulamalarında Türkiye'nin performansı ve öğrenci başarısını yordayan değişkenler. *Türkiye Sosyal Araştırmalar Dergisi*, 25(3), 905–926.
- Schloerke, B., Cook, D., Larmarange, J., Briatte, F., Marbach, M., Thoen, E., Elberg, A., & Crowley, J. (2024). *GGally: Extension to 'ggplot2'* (R package version 2.2.1). <https://CRAN.R-project.org/package=GGally>
- Sinharay, S. (2016). An NCME instructional module on data mining methods for classification and regression. *Educational Measurement: Issues and Practice*, 35(3), 38–54. <https://doi.org/10.1111/emip.12115>
- Steinberg, D., & Colla, P. (1995). *CART: Tree-structured nonparametric data analysis*. Salford Systems.
- Stevens, J. P. (2009). *Applied multivariate statistics for the social sciences*. Routledge.
- Strobl, C. (2013). Data mining. In T. D. Little (Ed.), *The Oxford handbook of quantitative methods in psychology: Vol. 2: Statistical analysis* (pp. 678–700). OUP USA.
- Strobl, C., Malley, J., & Tutz, G. (2009). An introduction to recursive partitioning: Rationale, application, and characteristics of classification and regression trees, bagging, and random forests. *Psychological Methods*, 14(4), 323–348. <https://doi.org/10.1037/a0016973>
- Şahin, M. G., & Yıldırım, Y. (2016). PISA 2012 Türkiye örnekleminde matematiksel davranış ve matematik okuryazarlığını etkileyen değişkenlerin çok gruplu hibrit modelleme ile incelenmesi. *Eğitim ve Bilim*, 41(187), 181–198. <https://doi.org/10.15390/EB.2016.6837>
- Tabachnick, B. G., & Fidell, S. F. (2020). *Çok değişkenli istatistiklerin kullanımı* (M. Baloğlu, Çev. Ed.). Nobel Yayıncılık. (Eserin orijinali 2013'te yayınlandı).
- Therneau, T. M., & Atkinson, E. J. (2023a). *An introduction to recursive partitioning using the RPART routines*. Mayo Foundation: Technical report.
- Therneau, T., & Atkinson, B. (2023b). *Recursive partitioning and regression trees*. <https://CRAN.R-project.org/package=rpart>
- Wickham, H., François, R., Henry, L., Muller, K., & Vaughan, D. (2023). *dplyr: A grammar of data manipulation* (R package version 1.1.4). <https://CRAN.R-project.org/package=dplyr>
- Wickham, H., Vaughan, D., & Girlich, M. (2024). *tidyr: Tidy messy data* (R package version 1.3.1). <https://CRAN.R-project.org/package=tidyr>
- Xie, Y. (2024). *knitr: A general-purpose package for dynamic report generation in R* (R package version 1.46). <https://yihui.org/knitr/>
- Yohannes, Y., & Webb, P. (1999). *Classification and regression trees, CART: A user manual for identifying indicators of vulnerability to famine and chronic food insecurity*. International Food Policy Research Institute.

Extended Abstract

Introduction

Classification and regression trees (CART), developed by Breiman et al. (1984), are nonparametric regression methods that involve predicting the value of the dependent variable using independent variables (Strobl, 2013). Regression trees (RT) are the nonparametric equivalent of multiple linear regression (MLR) analysis. It has been observed that research on the comparison of these two methods in education is limited. This study aims to compare RT and MLR analysis on a training data set, which can be seen as alternatives to each other in a relatively large data set. By discussing the strengths and weaknesses of both methods, it is hoped that the study will contribute to the literature with findings that will support the decision-making process of researchers on the analysis method. Accordingly, the research questions are as follows:

1. How are the predictive performances of RT and MLR analyses for mathematical literacy skills for the whole data set?
2. What is the order of importance of the variables that contribute to the prediction of mathematical literacy skills for both methods?
3. How are the predictive performances of RT and MLR analyses on mathematical literacy skills in 200 different sub-samples?

Method

The study used the responses of 6645 individuals (3293 female, 3352 male) from PISA 2022 Türkiye data. Accordingly, the dependent variable of the study is the first plausible value related to mathematical literacy skills. Various questionnaire items, indices and cognitive domain scores were used as independent variables.

Results

According to the results of the MLR analysis, the significant variables were PV1READ (reading literacy), MATHEFF (self-efficacy towards formal and applied mathematics), HOMEPOS (home possessions), ICTRES (ICT resources), ESCS (index of economic, social and cultural status), ST059Q02JA (number of weekly class hours), FAMCON (familiarity with mathematical concepts), MATHEFF21 (mathematical reasoning and self-efficacy towards 21st-century mathematics). Interpreting the coefficients, after controlling for the effects of other variables, a one-unit increase in reading comprehension score increases performance in math literacy by 0.754 units, a one-unit increase in the level of self-efficacy for formal and applied mathematics increases performance in mathematical literacy by 9.941 units, a one-unit increase in the home possessions variable increases performance in mathematical literacy by 8.392 units, a one-unit increase in the level of ownership of ICT resources leads to a 6.225 units decrease in performance in math literacy, a one-unit increase in economic/social and cultural status increases performance in mathematical literacy by 3.849 units, and a one-unit increase in weekly school hours increases performance in mathematical literacy by 0.266 units, a one-unit increase in the level of familiarity with mathematical concepts to increase performance in mathematical literacy by 1.957 units, a one-unit increase in the level of self-efficacy for mathematical reasoning and 21st century mathematics tends to increase the performance in mathematical literacy by 1.785 units.

According to the RT analysis, the resulting tree was interpreted. Accordingly, for example, when the divisions on the far left of the tree are analyzed, it is seen that those with reading literacy scores lower than 470, 391 and 329, respectively, tend to have the lowest mathematical literacy scores (average 331 points). When the divisions on the far right side of the tree are examined, it can be said that those whose reading literacy scores are greater than and equal to 470 and 543, respectively, and whose self-efficacy scores in formal and applied mathematics are greater than and equal to -0.19 tend to score the highest (average 584 points). On the other hand, the variable importance obtained according to the regression tree analysis result was PV1READ, MATHEFF, HOMEPOS, ICTRES, ESCS, ST059Q02JA, MATHEFF21 and FAMCON, respectively.

According to the metric values, it can be said that both models fit the data well. However, it is observed that MLR exhibits better forecasting performance according to all metric values. According to the findings obtained from the replication study, MLR performed better in all sub-samples according to MAE and bias metrics, in 199 sub-samples according to MAPE, correlation and explained variance, and in 198 sub-samples according to MSE and RMSE metrics. In addition, MLR analysis performed better in terms of average metric values.

Conclusion, Suggestions and Recommendations

In the study, the performance of RT and MLR analyses in predicting mathematical literacy and the importance rankings of independent variables were examined. First, according to the metric values, both methods perform well. However, it must be said that the MLR has better metric values. If the possible reasons for this result are examined, the data set used in the study is organized in a way that meets the assumptions and requirements of the MLR, which is a parametric technique. In addition, there are moderate and strong linear relationships between the variables used. Breiman et al. (1984) stated that the performance of RT can be much better than linear regression when there are no linear relationships, while the performance of RT tends to be slightly lower when there are strong linear relationships between variables. If there is a non-linear and complex relationship between variables, decision trees can outperform classical approaches (James et al., 2013). In this case, it is thought that the performance difference obtained may be due to the characteristics of the data set to a certain extent. However, it may also be misleading to establish a direct correlation that there is a performance difference in favor of the MLR because the data set meets the requirements of the MLR. Chowdhury et al. (2022) reported that tree-based models outperformed the MLR as a result of comparisons with a data set with multiple linear connections and skewed distribution. On the other hand, Piramuthu (2008) found that tree performance was negatively affected in the presence of nonlinear relationships and outliers. Inhomogeneity of variances did not have a significant effect, while the presence of multicollinearity did not negatively affect the performance of the trees. However, only forecasting performance has been analyzed in these studies. However, Piramuthu (2008) stated that multicollinearity would not be a problem in regression analysis if it is only aimed to make predictions, but it would be a problem when interpreting the coefficients and making inferences about the importance levels of the variables accordingly. In this context, it is thought that the purpose of the researcher and the characteristics of the data set will be decisive when making interpretations. As a result, it is thought that it would be useful to conduct studies in the literature that will enable more generalizable inferences to be made about the behavior of the methods according to the characteristics of the data set. On the other hand, the fact that RT with good performance is not subject to some assumptions and requirements as in the MLR suggests that regression trees are a preferable alternative in large, complex data sets containing a large number of predictors. At the same time, the

RT provides a more easily interpretable and understandable tree structure for the relationships between variables. To obtain such relationships in MLR, interaction terms should be added to the model by knowing the relationships beforehand. But this may not always be possible. In CART, complex interactions between independent variables need not be predetermined as in traditional statistical techniques. In this way, possible misidentification problems can be avoided, and complex and non-linear relationships that traditional methods cannot easily cope with can be detected (Ma, 2018; Strobl et al., 2009).

According to the second sub-problem of the study, it was observed that the rankings of important variables were almost the same in both methods. There are some studies examining the relationship between reading literacy, which is found to be the most important variable, and mathematics performance. For example, Güre et al. (2020) found that Turkish achievement level was among the important variables affecting mathematical literacy. The meta-analysis study conducted by Öztop & Toptaş (2022) reported a high positive correlation between mathematical literacy and reading literacy, regardless of years and educational levels (primary and secondary school). Therefore, it can be said that students who understand what they read better can make better sense of mathematical operations and concepts, and this contributes positively to performance. In many studies on self-efficacy for formal and applied mathematics, which ranks second in importance, it has been found that this trait level has a positive and/or significant relationship with mathematics performance (Aksu et al., 2017; Aksu & Güzeller, 2016; Aksu & Keceoglu, 2019; Kesici, 2018; Okatan & Tomul, 2020; Özkal, 2020; Şahin & Yıldırım, 2016).

Similarly, for the home possessions variable, which includes items such as having a room of one's own and having educational software or applications, some studies show that it positively affects math performance (Acar Güvendir, 2017; Karabay et al., 2015). Therefore, it is thought that having more possessions at home has a positive effect on performance as it increases accessibility and comfort. Another important variable was access to ICT. The effect of this variable was found to be negative according to the MLR analysis. It is thought that this situation may be related to the change in how ICT resources are used and that they are not frequently used for educational purposes. There are various studies showing that economic, social and cultural status is significantly and positively related to math performance (Aksu et al., 2020; Koğar, 2015; Guo, 2014; Okatan & Tomul, 2020; Ötken, 2019). Higher socio-economic status provides families with many supports and opportunities to contribute to their children's education. However, a strong relationship between socioeconomic status and performance also means a less equitable system (OECD, 2023b). In order to reduce the significant and positive relationship between mathematics performance and socio-economic status, it can be said that measures should be taken to eliminate social and educational injustice. The other important variable is the number of weekly class hours. According to the effect of this variable, which is positively related to mathematical literacy, it can be said that the increase in the number of course hours, including mathematics, has a positive effect on performance.

On the other hand, similar to this study, other studies have confirmed a positive relationship between mathematics performance and familiarity with mathematical concepts (Arıkan, 2016). Finally, a positive relationship was found between mathematical reasoning and self-efficacy for 21st-century mathematics and mathematical literacy. In addition to these, according to Sarier's (2021) qualitative review of the studies examining Türkiye's performance in PISA applications in the literature, it was reported that home possessions, economic, social and cultural status, and self-efficacy were among the important variables predicting mathematics, reading literacy, and science achievement as common findings of the studies conducted within the mentioned scope.

As a result, both models used in the study were found to be a good match for this data set. In addition, it is noteworthy that both methods yield consistent results regarding important variables. The results obtained are discussed in the context of the structure of the data set and the characteristics of the methods. It is suggested that researchers should decide on the analysis method by taking these situations into account.

The study has some limitations. Accordingly, only two methods were compared in the context of continuous and ordinal independent variables. At the same time, the first plausible value of mathematical literacy was used as the dependent variable. In further research, independent variables of different scale types can be used. At the same time, the performance of the methods on larger and/or smaller data sets can be examined. In addition, it was observed that the studies mentioned above were based on multicollinearity and linearity, normality of the data set but a small number of predictors and sample size. Therefore, future studies can be conducted to obtain more generalizable findings by examining the performance of the methods with data sets that contain more predictors, are larger and have various distributional characteristics. Comparisons can also be made with other machine learning algorithms that address some of the limitations of regression trees, such as ensemble learning methods and/or methods based on conditional inference trees.

Yayın Etiği Beyanı

Bu çalışmada ikincil veriler kullanılmıştır. Bu nedenle etik onay gerekli değildir. Bu araştırmanın planlanmasından, verilerin kullanılmasına ve verilerin analizine kadar olan tüm süreçte “Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi” kapsamında uyulması belirtilen tüm kurallara uyulmuştur. Yönergenin ikinci bölümü olan “Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler” başlığı altında belirtilen eylemlerden hiçbiri gerçekleştirilmemiştir. Bu araştırmanın yazım sürecinde bilimsel, etik ve alıntı kurallarına uyulmuş; kullanılan veriler üzerinde herhangi bir tahrifat yapılmamıştır. Bu çalışma herhangi başka bir akademik yayın ortamına değerlendirme için gönderilmemiştir.

Araştırmacıların Katkı Oranı Beyanı

Birinci yazar %70, ikinci yazar %30 oranında katkı sağlamıştır.

Çatışma Beyanı

Araştırmanın yazarları olarak herhangi bir çıkar/çatışma beyanımız olmadığını ifade ederiz.



Bu eser Creative Commons Atıf-GayriTicari 4.0 Uluslararası Lisansı ile lisanslanmıştır.