

Dijitalleşen Matematik Eğitimi ile Veri Madenciliği ve Öğrenme Analitiği

Tuğba Tuğ¹

Özet

Bu çalışmanın amacı, bilgi ve iletişim teknolojilerinin gelişimiyle eğitim ortamlarında biriken büyük verinin, Eğitimde Veri Madenciliği (EDM) ve Öğrenme Analitiği disiplinleri aracılığıyla matematik eğitimine nasıl entegre edilebileceğini yapısal olarak incelemek; literatürdeki algoritmik uygulamaları somutlaştırarak eğitim süreçlerine sağladığı katmanlı katkıları ve beraberinde getirdiği etik riskleri tartışmaktır.

Çalışma, nitel bir kavramsal analiz ve geniş kapsamlı bir literatür taraması niteliğindedir. Bu doğrultuda, öğrencilerin dijital ortamlardaki etkileşim logları, performans çıktıları ve duyuşsal verileri; Hiebert ve Lefevre'in (1986) "Kavramsal ve İşlemsel Bilgi", Schoenfeld'in (1992) "Matematiksel Düşünme", Zimmerman'ın (2002) "Öz-Düzenlemeli Öğrenme" ve Vygotsky'nin "Yakınsal Gelişim Alanı" (ZPD) kuramsal çerçeveleriyle ilişkilendirilerek analiz edilmiştir.

Yapılan literatür analizi sonucunda, matematik eğitiminde veri madenciliği uygulamalarının temelde üç ana ekseninde (başarı tahmini, kavram yanlılığı tespiti ve uyarlamalı geri bildirim) ivme kazandığı saptanmıştır. Bu süreçte kullanılan denetimli ve denetimsiz makine öğrenmesi tekniklerinin pedagojik karşılıkları şu şekilde tasnif edilmiştir. Ayrıca, oyun tabanlı ortamlarda öğrencilerin sıkılma veya hayal kırıklığı anlarının anlık tespit edilebildiği; Bayeşçi ve Derin Bilgi İzleme modelleriyle öğrenci ustalığının olasılıksal olarak haritalandırılabilirdiği belirlenmiştir.

Sonuç olarak, Eğitimde Veri Madenciliği tekniklerinin, geleneksel ve sonuç odaklı değerlendirme yaklaşımını "süreç odaklı ve biçimlendirici bir değerlendirme" kültürüne dönüştürdüğü görülmüştür. Bu bağlamda, gelecekteki sistemlerin Açıklanabilir Yapay Zeka prensiplerine uygun tasarlanması, Çok Modlu Öğrenme Analitiği ile duyuşsal boyutların da sürece dahil edilmesi ve yapay zekanın analitik gücü ile öğretmenin pedagojik alan bilgisini birleştiren iş birliğine dayalı bir "hassas eğitim" modelinin benimsenmesi önerilmektedir.

1 Dr. Öğr. Ü., Van Yüzüncü Yıl Üniversitesi, tugbatug@yyu.edu.tr ORCID: 0000-0002-7197-0747

1. Giriş

Bilgi ve iletişim teknolojilerindeki hızlı gelişim, eğitim süreçlerini geleneksel sınıf duvarlarının ötesine taşıyarak dijital öğrenme ortamlarının yaygınlaşmasını sağlamıştır. Bu platformların kullanımının artması, eğitim ortamlarında devasa boyutlarda veri birikimine yol açmaktadır. “Büyük Veri” olarak nitelendirilen bu yığın, öğrencilerin sisteme giriş saatlerinden, bir matematik problemini çözerken harcadıkları süreye, bilgisayar başında geçirdiği saatten sınav sonuçlarına kadar sayısız değişkeni barındırmaktadır. Teknolojinin öğretim süreçlerine entegre edilebilmesi için uzun yıllardır süren çalışmalar devam etmektedir. Yapılan çalışmalar ışığında teknoloji entegrasyonunun tek bir yolunun olmadığı savunulmaktadır (Koehler ve Mishra, 2009; Özmen, Koçak-Usluel ve Çelen, 2014).

Teknoloji öğrencilerin matematiksel düşünme yollarını geliştirmekte (Keong, Horani ve Daniel, 2005) ve matematiksel fikir ve düşünce günü desteklemektedir (Wachira ve Keengwe, 2011). Eğitim teknolojileri, öğrencileri motive etme ve matematik öğrenme sorumluluğu alma sürecinde etkili bir araç olmaktadır (Buteau ve Muller, 2006, s. 77)

Veri madenciliği, hacimce büyük olan veri kümeleri arasında neden-sonuç ilişkisini keşfetme olarak ifade edilebilir. Veri madenciliğinde kullanılan algoritmalar ile makine öğrenmesi yöntemleri etkin bir şekilde kullanılmaktadır. Makine öğrenmesi, büyük verinin bir kısmı üzerinde kendini eğiterek veriler arasındaki ilişkiyi çözümlenmeyi yani öğrenmeyi hedefleyen bir kavramdır (Kayri ve Şevgin,2023).

Bu bağlamda, Eğitimde Veri Madenciliği (EDM) ve Öğrenme Analitiği, ham veriyi pedagojik açıdan anlamlı bilgiye dönüştürme sürecinde çok önemli disiplinler olarak öne çıkmaktadır (Romero & Ventura, 2020). Özellikle soyut yapısı nedeniyle öğrencilerin çokça zorlandığı matematik eğitimi, veri madenciliği tekniklerinin en verimli şekilde uygulanabileceği alanların başında gelmektedir.

Eğitiminde veri madenciliği uygulamalarının son yirmi yılda ivme kazandığı ve çalışmaların; öğrenci başarısının tahmini, kavram yanlışlarının tespiti ve kişiselleştirilmiş geri bildirim mekanizmaları olmak üzere üç ana ekseninde toplandığı görülmektedir. İlk olarak, Öğrenci başarısının ve risk durumlarının tahmini araştırma konularının başında gelmektedir. Minaei-Bidgoli ve arkadaşları (2003) tarafından yapılan çalışmada, web tabanlı bir matematik/fizik eğitim sistemi olan LON-CAPA üzerindeki öğrenci logları incelenmiş; sisteme giriş sıklığı ve ödev tamamlama süreleri ile dönem sonu başarı puanları arasında anlamlı bir ilişki olduğu saptanmış ve genetik algoritmalarla başarı

tahmini yapılmıştır. Benzer şekilde, Sınıflandırma ve Regresyon algoritmaları kullanılarak yapılan çalışmalarda, öğrencilerin dersten zayıf not alma veya okul terki risklerinin dönem ortasında yüksek doğruluk oranlarıyla tahmin edilebildiği belirtilmiştir (Kotsiantis, 2012). Bu çalışmalar, veri madenciliğinin erken uyarı sistemleri geliştirilmesindeki rolünü gözler önüne sermektedir.

İkinci önemli nokta, kavram yanlışlarının ve problem çözme stratejilerinin analizidir. Matematik öğretiminde sonucun doğruluğunun önemi kadar, o sonuca giden yolun analizi de oldukça önemlidir. Merceron ve Yacef (2005), mantık ve matematik öğretiminde kullanılan bir eğitim yazılımından elde edilen veriler üzerinde “Birliktelik Kuralları” (Association Rules) yöntemini kullanarak, öğrencilerin yaptıkları hataların rastgele olmadığını, özellikle öğrencilerin yaptığı belirli yanlışların sistematik olarak birbirini tetiklediğini ortaya koymuştur. Bu tür analizler, öğretim programlarının öğrencilerin sık düştüğü yanlışları giderecek şekilde yeniden düzenlenmesine olanak tanımaktadır.

Üçüncü olarak, en dinamik çalışma sahalarından biri olan uyarlanabilir (adaptive) öğrenme sistemleri ve kişiselleştirilmiş geri bildirim çalışmalarıdır. Corbett ve Anderson (1995) tarafından geliştirilen “Bilgi İzleme” (Knowledge Tracing) modeli, öğrencinin matematiksel becerilerdeki gelişimlerini zaman içindeki performansına göre olasılıksal olarak modellemiş ve modern akıllı öğretim sistemlerinin temelini atmıştır. Bunların dışında Kümeleme (Clustering) analizleri ile öğrencileri öğrenme stillerine veya etkileşim desenlerine göre gruplara ayıran çalışmalar da her gruba özgü farklılaştırılmış matematik öğretimi sunulmasının önemini vurgulamaktadır (Vahdat ve ark., 2015).

Bilgi çağında eğitim paradigmaları hızla dönüşürken, matematik eğitimi de bu değişimden payını almakta ve teknoloji destekli öğrenme ortamları giderek yaygınlaşmaktadır. Fakat bu yaygınlaşma matematik öğretiminin pedagojik zorluklarını tek başına ortadan kaldırmamaktadır. Matematik eğitimi ile ilgili çalışmalar incelendiğinde, öğrenme sürecinin sadece bilişsel değil, aynı zamanda duyuşsal ve üstbilişsel boyutları da içeren bir yapı olduğu görülmektedir (Schoenfeld, 1992). Bu durum, öğrencilerin matematiksel kavramları yapılandırma süreçlerinin, geleneksel ölçme araçlarıyla tam olarak anlaşılabilmesi sorununu ortaya çıkarmaktadır.

Eğitimde Veri Madenciliği ile ilgili çalışmalar sadece sonuç odaklı başarı tahminleriyle sınırlı kalmadığı; bilişsel modellemeden öz-düzenlemeli öğrenme becerilerine kadar geniş bir alana yayıldığı görülmektedir.

Matematik eğitimi alanındaki temel çalışmalar, öğrenmenin kavramsal anlama ve işlemsel akıcılık arasındaki dengeye dayandığını vurgulamaktadır

(Hiebert & Lefevre, 1986; Kilpatrick et al., 2001). Geleneksel araştırmalar, kavram yanlışlarını genel olarak sınırlı çalışmalarla tespit etmeye çalışırken; veri madenciliği teknikleri, çok fazla öğrencinin aynı anda problem çözme adımlarını analiz edebilmektedir. Bu bağlamda, literatürde Bayeşçi Bilgi İzleme (Bayesian Knowledge Tracing) ve son yıllarda büyük bir ilgi gören Derin Bilgi İzleme (Deep Knowledge Tracing) modelleri öne çıkmıştır. (Corbett & Anderson, 1995) tarafından temelleri atılan bu modeller, öğrencinin her bir matematiksel becerideki ustalığını (mastery) zaman içindeki performansına göre olasılıksal olarak modellemektedir.

Matematik, sadece formüllerin uygulanarak çözüme ulaşılmasından ibaret değildir. Aynı zamanda problemin çözüm sürecinin planlanması ve izlenmesi de büyük önem taşımaktadır. Öz-Düzenlemeli Öğrenme (Self-Regulated Learning) olarak adlandırılan bu süreç, matematik dersinde başarı gösteren öğrencileri diğer öğrencilerden ayıran temel faktörlerden biridir (Zimmerman, 2002).

Bunların dışında, öğrencilerin matematik dersinde başarılı olamama kaygısı, tutum ve motivasyonu, akademik başarıyı doğrudan etkileyen duyuşsal faktörler olduğu görülmektedir. Veri madenciliği ile entegre edilen modern araştırmalar, bu faktörleri anlık olarak tespit etmeye odaklanmaktadır. Özellikle Oyun Tabanlı Öğrenme (Game-Based Learning) ortamlarında yapılan veri madenciliği çalışmaları, öğrencilerin akış deneyimini ölçmede önemli bir rol oynamaktadır. (Shute, 2011) çalışmasında dijital matematik oyunlarındaki oyuncu etkileşimlerini analiz ederek, öğrencinin sıkılma (boredom) veya hayal kırıklığı (frustration) yaşadığı anları tespit etmiş; oyunun zorluk seviyesini dinamik olarak ayarlayan adaptif sistemler önermiştir. “Gizli Değerlendirme” (Stealth Assessment) olarak adlandırılan bu yaklaşım öğrencilerin sınav kaygısı yaşamadan matematiksel yetkinliklerinin ölçülmesine olanak tanımını belirtmiştir.

Eğitimde Veri Madenciliği konusunda çalışmaların genişlemesinin önemli bir ayağını da öğretmenlere sunulan geri bildirim mekanizmaları oluşturmaktadır. Veri madenciliğinin sadece araştırmacılar veya algoritmalar için değil, sınıf içi uygulamalar için de bir araç olması gerektiği vurgulanmaktadır.

Yapılan araştırmalar ve çalışmalar veri madenciliğini; bilişsel, üstbilişsel ve duyuşsal boyutlarıyla matematik eğitiminin çok katmanlı yapısını çözümlenmede bütüncül bir yaklaşım olarak konumlandırmaktadır. Bu çalışmada da söz konusu teorik temeller ışığında, veri madenciliği tekniklerinin matematik eğitimindeki pratik uygulamalarını ve gelecekteki potansiyellerini tartışmayı amaçlamaktadır.

Çalışmalar incelendiğinde, veri madenciliğinin matematik eğitiminde tanılayıcı ve iyileştirici bir rol oynadığı görülebilir. Ancak, teknik algoritmaların matematiksel düşünme ve problem çözme teorileriyle nasıl daha etkin birleştirilebileceği konusunda daha derinlemesine çalışmalara ihtiyaç vardır Schoenfeld (1992).

Bu çalışma, matematik eğitiminde kullanılan temel veri madenciliği tekniklerini, literatürdeki gerçek uygulama örnekleri ışığında ele alarak; eğitimciler ve araştırmacılar için teorik ve pratik bir çerçeve sunmayı amaçlamaktadır.

2. Matematik Eğitiminde Veri Madenciliği Uygulamaları

Matematik eğitiminde veri madenciliği uygulamaları, ham verinin toplanmasından pedagojik olarak işlenmesine kadar uzanan çok aşamalı ve döngüsel bir süreçten oluşmaktadır. Bu çerçeve; veri kaynaklarının çeşitliliği, kullanılan algoritmaların matematiksel doğası ve hedeflenen pedagojik çıktılar olarak ele alınabilir.

2.1. Veri Kaynakları ve Ön İşleme (Data Sources & Pre-processing)

Veri madenciliğinin başarısı, toplanan verinin kalitesi ve çeşitliliği ile doğrudan ilişkilidir. Matematik eğitimi araştırmalarında kullanılan veri setleri, yapılandırılmış ve yapılandırılmamış olmak üzere iki temel kategoride toplanmaktadır:

- **Etkileşim Logları (Interaction Logs):** Öğrenme Yönetim Sistemleri (Moodle, Blackboard vb.) veya Akıllı Öğretim Sistemleri (ITS) üzerinden elde edilen verilerdir. Matematik özelinde bu veriler; bir problemin çözüm süresi, kullanılan ipucu sayısı, GeoGebra sürgüleri gibi sanal manipülatiflerin hareket dökümleri gibi ince taneli (fine-grained) değişkenleri içerir.
- **Performans Verileri:** Geleneksel sınav sonuçları, ödev notları ve süreç değerlendirme puanlarını kapsar.
- **Psikometrik ve Duyuşsal Veriler:** Matematik kaygısı ölçekleri, tutum anketleri veya göz izleme (eye-tracking) cihazlarından elde edilen odaklanma verileridir.

Bu ham veriler, algoritmaların işleyebileceği formata getirilmek üzere Veri Ön İşleme aşamasından geçer. Bu aşamada, gürültülü verilerin temizlenmesi, eksik verilerin tamamlanması ve en önemlisi Öznitelik Çıkarımı (Feature Extraction) işlemleri gerçekleştirilir. Örneğin, ham log kayıtlarındaki “tıklama

sayısı”, matematiksel bir bağlamda “çaba göstergesi” veya “kararsızlık katsayısı” gibi anlamlı özniteliklere dönüştürülür.

2.2. Temel Algoritmalar ve Teknikler

Matematik eğitimindeki veriler analiz edilirken, araştırma sorusunun doğasına göre farklı makine öğrenmesi teknikleri ve istatistiksel algoritmalar kullanılmaktadır. Bunların içinde öne çıkan Sınıflandırma, Kümeleme ve Birliktelik Kuralı Madenciliği en temel yöntemlerdir.

2.2.1. Sınıflandırma (Classification)

Öğrencileri önceden tanımlanmış; başarılı-başarısız, riskli-risksiz gibi etiketlere atamak için kullanılır. Sınıflandırmada kullanılan algoritmalar Karar Ağaçları (Decision Trees), Destek Vektör Makineleri ve Sinir Ağlarıdır. Karar Ağaçları; Matematik eğitimcileri tarafından en sık tercih edilen algoritmalarından biridir. “Eğer-İse” mantığıyla çalıştığı için sonuçları öğretmenler tarafından kolayca yorumlanabilir. Destek Vektör Makineleri (SVM) ve Sinir Ağları ise daha karmaşık ve doğrusal olmayan veri setlerinde yüksek doğruluklu tahminler yapmak için kullanılır.

2.2.2. Kümeleme (Clustering)

Veri setindeki öğrencileri, önceden belirlenmiş bir etiket olmaksızın benzer özelliklerine göre gruplara ayırır (Denetimsiz Öğrenme). Kümeleme yapılırken en yaygın kullanılan algoritma, K-Means Algoritmasıdır. K-Means Algoritması, öğrencileri öğrenme stillerine veya hata yapma örüntülerine göre homojen gruplara ayırmak için yaygın olarak kullanılır. Örneğin, bir geometri dersinde “görsel ağırlıklı çalışanlar” ile “analitik çözüm yapanlar” bu yöntemle ayrıştırılabilir.

2.2.3. Birliktelik Kuralı Madenciliği (Association Rule Mining)

Veriler arasındaki gizli ilişkileri ve “birlikte görülme” sıklıklarını ortaya çıkarır. Apriori Algoritması kullanılır. Apriori Algoritması, özellikle kavram yanlışlarının analizinde etkilidir. “*X hatasını yapan öğrenci, %85 olasılıkla Y hatasını da yapmaktadır*” şeklindeki kuralların tespiti, matematik müfredatının sıralanmasında önemli rol oynar.

2.3. Uygulama Alanları: Teknikten Pedagojiye

Yukarıda belirtilen algoritmalar, matematik eğitiminde somut pedagojik sorunları çözmek amacıyla, Kavram Yanılgısı Tespiti ve Onarımı, Erken Uyarı Sistemleri ve Uyarlanabilir İçerik Sunumu gibi birçok alanda uygulanmaktadır.

- **Kavram Yanılgısı Tespiti ve Onarımı:** Birliktelik kuralları ve süreç madenciliği kullanılarak, öğrencinin sadece yanlış cevabı değil, aynı zamanda o yanlış giden bilişsel süreci belirlenir. Bu sayede sisteme, öğrencinin hatasına spesifik bir geri bildirim verme yeteneği kazandırılır.
- **Erken Uyarı Sistemleri (Early Warning Systems):** Sınıflandırma algoritmaları ile akademik başarısızlık riski taşıyan öğrenciler dönem başında tespit edilir. Bu tespit, öğretmene müdahale şansı tanır.
- **Uyarlanabilir (Adaptive) İçerik Sunumu:** Bilgi İzleme (Knowledge Tracing) modelleri kullanılarak, öğrencinin matematiksel yetkinlik düzeyi anlık olarak hesaplanır. Sistem, öğrenciye sıkılacağı ne çok kolay, ne de öğrenciye kaygı verici çok zor sorular sorar. Bunun yerine “yakınsal gelişim alanına” (ZPD) uygun içerikler sunar.

Özetle, matematik eğitiminde veri madenciliği uygulamaları; teknik algoritmaların sıkıcı mantığını, pedagojik teorilerin sıcak ve insan odaklı yapısıyla birleştiren disiplinler arası bir köprü görevi görmektedir.

3. Veri Madenciliğinin Eğitim ve Öğretim Süreçlerine Katkıları

Matematik eğitiminde veri madenciliği uygulamaları, sadece akademik bir araştırma alanı olmanın ötesinde, sınıf içi öğretim pratiklerini ve öğrenme deneyimlerini dönüştürme potansiyeline sahiptir. Büyük verinin pedagojik amaçlarla işlenmesi, eğitimin gerek öğrenci, gerek öğretmen, gerek program geliştiricisi olmak üzere tüm paydaşlarına stratejik avantajlar sunmaktadır. Bu katkılar; Bireyselleştirilmiş Öğretim ve Uyarlanabilirlik, Öğretmenler İçin Karar Destek Mekanizması, Süreç Odaklı ve Biçimlendirici Değerlendirme ve Kanıta Dayalı Müfredat ve İçerik Geliştirme olmak üzere dört alt başlık olarak incelenebilir.

3.1. Bireyselleştirilmiş Öğretim ve Uyarlanabilirlik

Geleneksel sınıf ortamında bir öğretmenin her öğrencisinin hızına ve seviyesine aynı anda hitap etmesi çok da mümkün değildir. Bu durumda, Veri madenciliği, Vygotsky'nin “Yakınsal Gelişim Alanı” (Zone of Proximal Development) teorisini dijital ortamda hayata geçirir. Bu teorisinin katkısı şu şekilde açıklanabilir. Sistem, öğrencinin geçmiş performans verilerini analiz ederek, ona ne çok kolay (sıkıcı) ne de çok zor (kaygı verici) sorular sorar. Öğrenciye özel bir öğrenme yol haritası çizilir. Örneğin, geometri konusunda yetkin olup ancak cebirde zorlanan bir öğrenciye, sistem otomatik olarak cebir ağırlıklı ek alıştırma desteği sunarak pratik yapmasına olanak tanır.

3.2. Öğretmenler İçin Karar Destek Mekanizması

Öğretmenler sınıf ortamını kalabalık olması, öğrencinin biliş seviyesini fark etmesinin zaman alması gibi nedenlerle; öğrencilerin öğrenme eksikliklerini sınav sonuçlarından sonra fark edebilirler. Bu geç kalınmışlığın önüne geçmek için Veri madenciliği, öğretmene “gerçek zamanlı bir içgörü” sağlar. Böylece eğitici kendisine sunulan öğretmen panelleri sayesinde, sınıfa girmeden önce hangi öğrencinin öğretmenin vermiş olduğu ödevi yaparken nerede takıldığını bilir. “Sınıfın %70’i basit kesir ve bileşik kesri kavramakta zorlanıyor” gibi somut bir veriyle derse başlayan öğretmen, bu sayede ders planını anlık olarak revize ederek güncelleyebilir. Bu durum, öğretmenin rolünü bilgi aktarıcı olmaktan çıkarıp bir nevi veri odaklı bir öğrenme koçuna dönüştürür.

3.3. Süreç Odaklı ve Biçimlendirici Değerlendirme

Her derste olduğu gibi matematik dersinde de en önemli sonuçlardan biri ölçme değerlendirme şamasıdır. Matematik eğitiminde sıkça eleştirilen sadece sonucun doğru veya yanlış olmasına kilitlenen “sonuç odaklı değerlendirme”, veri madenciliği ile yerini “süreç odaklı değerlendirme” ye bırakır. Böylece öğrencinin bir problemi çözerken kaç saniye düşündüğü, sildiği cevabı neden sildiği, soruyu çözüm aşamalarında hangi yöntemleri uyguladığı, ipucuna ihtiyaç duyup duymadığı gibi süreç verileri değerlendirmeye katılır. Bu sayede, soruyu doğru çöze bile kavramsal temeli zayıf olan ve sonucu tahmin ederek bulan öğrenciler tespit edilebildiği gibi aynı zamanda sonucu yanlış bulan fakat soruyu çözme aşamalarında doğru yöntemler geliştirerek işlem hatası gibi nedenlerle hata yapan öğrenciler tespit edilir. Bu yaklaşım, not vermekten ziyade öğrenmeyi iyileştirmeyi amaçlayan biçimlendirici değerlendirme (formative assessment) kültürünü güçlendirir.

3.4. Kanıta Dayalı Müfredat ve İçerik Geliştirme

Eğitim materyallerinin ve müfredatın etkinliği genellikle uzman görüşlerine dayanarak belirlenir. Veri madenciliği ise bu sürece nesnel kanıtlar sunar. Binlerce öğrencinin etkileşim verileri incelenerek, ders kitaplarındaki veya dijital içeriklerdeki sorunlu alanlar tespit edilebilir. Örneğin, “5. Ünite’deki 7. problemde öğrencilerin %95’i sistemi terk ediyor” bulgusu, o içeriğin pedagojik açıdan sorunlu olduğunu veya sırasının yanlış olduğunu gösterir. Böylece müfredat programları, varsayımlara değil, öğrenci davranış verilerine dayalı olarak yeniden optimize edilir.

Özetle; veri madenciliğinin eğitime entegrasyonu, öğrenci için kişiselleştirilmiş bir yol haritası, öğretmen için güçlü bir asistan, eğitim sistemi içinse sürekli iyileştirme aracı işlevi görmektedir.

4. Tartışma, Sonuç ve Öneriler

Bu çalışma, Eğitimde Veri Madenciliği (EDM) uygulamalarının matematik öğretiminde köklü bir paradigma değişimine işaret ettiğini göstermektedir. Matematik eğitiminde geleneksel ölçme ve değerlendirme yöntemlerinin ötesine geçerek, öğrenme süreçlerinin “büyük veri” perspektifiyle nasıl analiz edilebileceğini teorik ve pratik boyutlarıyla ele almıştır. Ele alınan vaka analizi ve literatür bulguları, sonuç odaklı değerlendirmeden, süreç odaklı analitik bir değerlendirmeye geçişin önemini vurgulamaktadır.

Çalışmalarda elde edilen bulgular, öğrenci hatalarının rastlantısal olmadığını, aksine belirli bilişsel şemaların ve kavram yanılgılarının sistematik birer yansıması olduğunu doğrulamaktadır. Özellikle “eşitliğin korunumu” ilkesindeki eksikliğin “işaret hatalarını” tetiklemesi, matematik eğitimcilerinin yıllardır vurguladığı “*Hata, öğrenmenin bir parçasıdır*” ilkesini veriye dayalı olarak kanıtlamaktadır. Bu bağlamda veri madenciliği, öğretmene sınıftaki “görünmeyen” bilişsel süreçleri görünür kılan bir mercektir.

Eğitimde dikkat çekici bir şekilde ön plana çıkan teknolojik ilerleme, öğretmenin rolünü azaltmamakta, aksine daha nitelikli hale getirmektedir. Algoritmalar “öğrencinin nerede hata yaptığını” tespit etmekte mükemmel araçlardır; fakat öğrencinin neden o hatayı yaptığını dair fikir yürütme ve tespitte bulunma ve öğrenciye duygusal destek sağlama görevi ise öğretmene aittir. Algoritmalar bu durumda yetersiz kalmakta, insan faktörü ön plana çıkmaktadır. Bu nedenle matematik eğitimi ile ilgili müfredat programları oluşturulurken öğretmenin pedagojik bilgisi, tecrübesi ile yapay zekanın analitik gücünün birleştiği iş birliğine dayalı bir zemin üzerine kurulmalıdır.

Fakat yapay zekanın analitik gücünden faydalanırken veri madenciliğinin sunduğu fırsatların yanı sıra, beraberinde getirdiği etik riskler de göz ardı edilmemelidir. Öğrencilerin dijital ayak izlerinin toplanması ve işlenmesi yasal çerçevelerle sıkı bir şekilde denetlenmeli öğrencilerin veri mahremiyeti etik çerçevede göz önünde bulundurulmalıdır. Ayrıca, eğitim verileriyle eğitilen algoritmaların, belirli öğrenci gruplarına; örneğin belirli bir sosyo-ekonomik düzeydeki öğrencilere karşı önyargılı tahminler üretme riski vardır. Bir öğrencinin sistem tarafından erkenden “başarısız olacak” şeklinde etiketlenmesi, öğrenci motivasyonunu olumsuz yönde etkileyerek başarısız olması riski oluşturabilir. Öğretmenin veri madenciliği hakkında yeterli akademik bilgiye sahip olmaması, Derin Öğrenme gibi karmaşık modellerin nasıl karar verdiğini bilmemesi, eğitimcilerin sisteme olan güven düzeyini etkileyebilir. Bu nedenle, matematik eğitiminde kullanılacak yapay zeka modellerinin “Açıklanabilir Yapay Zeka” (Explainable AI - XAI) prensiplerine uygun tasarlanması oldukça önemlidir.

Günümüzde Matematik eğitiminde veri madenciliğinin kullanılması sadece log kayıtlarının analiziyle sınırlı kalmamakta, Çok Modlu Öğrenme Analitiği çalışmaları ile öğrencilerin yüz ifadeleri, göz hareketleri (eye-tracking) de analizlere dahil edilmeye başlamıştır. Böylece bir öğrencinin matematik problemi çözerken yaşadığı “bilişsel yük” veya “anlık kaygı” gerçek zamanlı olarak tespit edilebilecektir.

Sonuç olarak; veri madenciliği, matematik eğitimini klişeleşmiş geleneksel öğretim yöntemlerinden kurtarıp, her öğrencinin kendi biliş seviyesinde ve hızında ilerleyebildiği, hatanın cezalandırma yerine bir öğrenme fırsatına dönüştürüldüğü hassas eğitim (precision education) modeline taşımaktadır.

Kaynakça

- Buteau, C. & Muller, E. (2006). *Evolving technologies integrated into undergraduate mathematics education*. Proceedings for the seventeenth ICMI study Conference. 74-81.
- Corbett, A. T., & Anderson, J. R. (1995). Knowledge tracing: Modeling the acquisition of procedural knowledge. *User Modeling and User-Adapted Interaction*, 4(4), 253-278.
- Hiebert, J., & Lefevre, P. (1986). Conceptual and procedural knowledge in mathematics: An introductory analysis. In J. Hiebert (Ed.), *Conceptual and procedural knowledge: The case of mathematics* (pp. 1-27). Lawrence Erlbaum Associates.
- Kaya, G. & Koçak Usluel, Y. (2011). *Öğrenme-öğretme süreçlerinde BİT entegrasyonunu etkileyen faktörlere yönelik içerik analizi*. Buca Eğitim Fakültesi Dergisi, 31, 48-67.
- Kayri, M., & Şevgin, H. (2023). *Eğitimde Veri Madenciliği ve Bilgisayar Uygulamaları*. Pegem Akademi.
- Keong, C.C., Horani, S. & Daniel, J. (2005). *A study on the use of ICT in mathematics teaching*.
- Kilpatrick, J., Swafford, J., & Findell, B. (Eds.). (2001). *Adding it up: Helping children learn mathematics*. National Academy Press.
- Koedinger, K. R., & Aleven, V. (2007). Exploring the assistance dilemma in experiments with cognitive tutors. *Educational Psychology Review*, 19(3), 239-264.
- Koehler, M. & Mishra, P. (2009). What is technological pedagogical content knowledge (TPACK). *Contemporary Issues in Technology Teacher Education*, 9(1), 60-70.
- Kotsiantis, S. B. (2012). Use of machine learning techniques for educational proposals: A decision support system for forecasting students' grades. *Artificial Intelligence Review*, 37(4), 331-344.
- Merceron, A., & Yacef, K. (2005). Educational Data Mining: A Case Study. *Artificial Intelligence in Education*, 125, 467-474.
- Minaei-Bidgoli, B., Kashy, D. A., Kortemeyer, G., & Punch, W. F. (2003). Predicting student performance: an application of data mining methods with an educational web-based system. *Frontiers in Education, 2003. FIE 2003 33rd Annual*. IEEE.
- Mishra, P. & Koehler, M.J. (2006). Technological pedagogical content knowledge: A framework for teacher knowledge. *Teachers College Record*, 108(6), 1017-1054.

- 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.
- Romero, C., & Ventura, S.** (2020). Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(3), e1355.
- Schoenfeld, A. H.** (1992). Learning to think mathematically: Problem solving, metacognition, and sense making in mathematics. In D. A. Grouws (Ed.), *Handbook of research on mathematics teaching and learning* (pp. 334-370). Macmillan.
- Shute, V. J.** (2011). Stealth assessment in computer-based games to support learning. In S. Tobias & J. D. Fletcher (Eds.), *Computer games and instruction* (pp. 503-524). Information Age Publishers.
- Vahdat, M., Ghio, A., Oneto, L., Anguita, D., Funk, M., & Rauterberg, M.** (2015). Advances in learning analytics and educational data mining. *European Symposium on Artificial Neural Networks*.
- Wachira, P. & Keengwe, J.** (2011). *Technology integration barriers: Urban school mathematics teachers perspectives*. *Journal of Science Education Technology, Knowledge, Learning*, 20(1), 17-25. <https://doi.org/10.1007/s10956-010-9230-y>
- Zimmerman, B. J.** (2002). Becoming a self-regulated learner: An overview. *Theory into Practice*, 41(2), 64-70.