



Yapay Zekâ Destekli Sınıf Yönetimi Becerileri Ölçeği*

Artificial Intelligence- Supported Classroom Management Skills Scale

Ercan YILMAZ, Burak GÜNER

Yazar Bilgileri

ÖZ

Ercan Yılmaz

Prof. Dr., Necmettin Erbakan
Üniversitesi, Eğitim Bilimleri
Bölümü

ercanyilmaz70@gmail.com

ORCID: 0000-0003-4702-1688

Burak Güner

Milli Eğitim Bakanlığı

burakguner55@gmail.com

ORCID: 0000-0002-1734-987X

Bu araştırma kapsamında yapay zekâ destekli sınıf yönetimi becerilerini ölçebilen geçerli ve güvenilir bir ölçme aracı geliştirme amaçlanmıştır. Yapay zekâ destekli sınıf yönetimi becerileri ölçeği, dijital sınıf yönetimi ve yapay zekâ destekli sınıf yönetimi literatürüne göre tasarlanmıştır. Ölçeğin geliştirilme aşamasında açımlayıcı faktör analizi için 239 öğrenciden, doğrulayıcı faktör analizi için ise 247 öğrenciden veri toplanmıştır. Pilot uygulamada ise, maddelerin anlaşılabilirliği ve ölçme aracının süresinin belirlenmesi gibi diğer aşamalarda ise toplamda 78 öğrenciden veri toplanmıştır. Ölçeğin yapı geçerliği ilk olarak AFA ve sonrasında ise DFA ile sınanmıştır. Yapılan analizler sonucunda ölçek toplamda 22 madde ve üç alt boyuttan oluşmuştur. Ölçeğin alt boyutları, yapılan literatür taraması sonucunda yapay zekâ destekli ve dijital sınıf ortamlarının yönetiminde bulunması gereken yeterlikleri kapsadığından, “yapay zekâ entegrasyonu, dijital etkileşim ve teknopedagojik altyapı” olarak isimlendirilmiştir. Mc’Donals Omega, Cronbach Alpha ve Ave hesaplanarak ölçeğin güvenilirliği test edilmiş ve ölçeğin hem alt boyutlarının hem de toplamının güvenilir bir yapıya sahip olduğu görülmüştür. Çalışma kapsamında yapılan analizler ölçeğin belirlenen niteliği ölçebilen, yüksek düzeyde geçerli ve güvenilir bir ölçme aracı olduğunu göstermiştir.

Makale Bilgileri

ABSTRACT

Anahtar Kelimeler

Yapay zekâ
Dijital sınıf
Dijital sınıf becerileri
Yapay zekâ yeterlikleri

Keywords

Artificial intelligence
Digital classroom
Digital classroom skills
Artificial intelligence
competencies

Makale Geçmişi

Geliş: 25.12.2025

Düzeltilme: 02.04.2026

Kabul: 08.06.2026

This study aimed to develop a valid and reliable measurement tool capable of assessing artificial intelligence-supported classroom management skills. The artificial intelligence-supported classroom management skills scale was designed based on the literature on digital classroom management and artificial intelligence-supported classroom management. During the development phase of the scale, data was collected from 239 students for exploratory factor analysis and 247 students for confirmatory factor analysis. Data was also collected from a total of 78 students during other phases, such as the pilot application, item comprehensibility, and determining the duration of the measurement tool. The construct validity of the scale was first tested with EFA and then with CFA. The analyses revealed that the scale consists of a total of 22 items and three subscales. As the subscales of the scale cover the competencies required for the management of AI-supported and digital classroom environments, based on a literature review, the dimensions of the scale were named “AI integration, digital interaction, and technopedagogical infrastructure.” The reliability of the scale was tested by calculating Mc’Donals Omega, Cronbach Alpha, and Ave, and it was found that both the sub-dimensions and the total of the scale have a reliable structure. The analyses conducted within the scope of the study showed that the scale is a highly valid and reliable measurement tool that can measure the specified quality.

Makale Türü

Araştırma

Önerilen Atıf Yılmaz, E. & Güner, B. (2026). Yapay zekâ destekli sınıf yönetimi becerileri ölçeği. *SEBED*, 1, 1-28.

1. GİRİŞ

Dünya üzerinde yaşanan değişimler her alanda olduğu gibi eğitim- öğretime de etki etmiştir. Geçmişten günümüze gelişen teknoloji sayesinde eğitim- öğretimin gerçekleştiği, öğretmenler ve öğrencilerin bir arada bulunduğu okullar ve sınıflar da değişimlere uğramıştır. Aynı zamanda bu değişimler bireylerin ihtiyaçlarında da ortaya çıktığı için öğrenciler ve öğretmenler üzerinde de büyük değişimler görülmeye başlanmıştır. Bu nedenle sınıf yönetimi kavramı; ortamların, öğrenci- öğretmen ihtiyaçlarının ve beklentileri değişen bireylerin adaptasyonu için günümüzde yeniden şekillenmeye başlamıştır. Geleneksel sınıf yönetimi kavramı, öğretmenlerin sınıfta otoriter olduğu, sınıfı sürekli kontrol ettiği ve sınıf disiplini sağlaması olarak tanımlanmaktadır (Aytaçlı, 2021; Taşdan & Yurttaş, 2022; Turan, 2020). Yani değişimler öncesi sınıf yönetimi kavramı disiplin ve davranış kavramları üzerine odaklanmıştır (Ada & Baysal, 2020). Ancak Erdoğan (2019) sınıf yönetimi kavramını, yaşanan değişimler nedeniyle bozulan dengelerin, günümüzde var olan şartlar ve yeni değerler ile yeniden şekillenebilen bir disiplin olarak tanımlamaktadır. Bu tanımdan yola çıkarak günümüzde yeni bir sınıf yönetim modeline ihtiyaç olduğu düşünülebilir.

Dijitalleşme ile ortaya çıkan yapay zekânın, dijital sınıf ortamlarına entegrasyonu geleneksel sınıf yönetimlerinin yanı sıra öğretmenlerin idari yüklerini azaltma, öğrenci davranışlarını tahmin edebilme ve bireyselleştirilmiş eğitim gibi büyük değişimlere zemin hazırlamıştır. Yapay zekâ, eğitim-öğretim süreçlerini otomatikleştirerek ve bireyselleştirerek dijital sınıf ortamlarında yönetimi sağlamada önemli bir araçtır (Li, 2024). Çünkü dijital sınıf ortamlarında sağlanan öğrenme analitiği, öğrenci takibi, geri dönütler ve içerik yönlendirmesi yapay zekânın entegrasyonu ile daha başarılı bir şekilde yapılabilmektedir.

Yapay zekâ destekli bir dijital sınıf ortamında öğrencilerin davranış biçimleri analiz edilerek öğretmenlerin önlemsel (proaktif) davranması ve öğrencilere yönelik destek çalışmalarını, öğrencilerin ihtiyaçlarını karşılayacak düzeyde uyarlamalarına olanaklar sağlamaktadır (Badawy vd., 2024; Gomez vd., 2025; Zhan & Cui, 2023). Örneğin, Almuqhim & Berri (2025), YZ destekli sınıf ortamında elde edilen öngörücü algoritmaların, öğrencilerin ders katılım ve performans ölçümlerini dikkate alarak, hangi öğrencinin risk altında olduğunu ortaya çıkarıp, öğretmenlerin bu öğrenciler için bireyselleştirilmiş dönütler yapmasına imkan sağlayacağını belirtmişlerdir (Zhou, 2024). Ancak öğretmenler, öğrencilerin ihtiyaçlarıyla uyumayan hatalı kararlardan kaçınabilmek için yapay zekâ tarafından oluşturulan önerileri eleştirel bir şekilde değerlendirebilmelilerdir (Al-Sindi vd., 2023). Sonuç olarak, öğretmenlerin yapay zekâ ve dijital becerilerinin eksikliği; öğrenci verilerinin kötüye kullanımı, siber güvenlik açıkları ve yapay zekâ sistemlerinden alınan verileri hatalı değerlendirme gibi riskler ortaya çıkarmakla beraber öğretmenlerin bu alanlarda kapsamlı eğitimler almasının önemi anlaşılmaktadır. Öğretmenlerin dijital ve yapay zekâ temelli araçları etkili şekilde kullanma becerilerini geliştirmek, çevrim içi sınıf ortamlarında öğrenme süreçlerinin kalitesini artırmak için gereklidir. Çünkü öğretmenlerin sahip olacağı bu beceriler, bireyselleştirilmiş ve kapsayıcı öğrenme ortamları oluşturma, hızlı dönüt verme, iş birliğini geliştirme ve etik veri kullanımı sayesinde öğrenme çıktılarını iyileştirme fırsatı sağlar. Aynı zamanda dijital araçların bilinçli yönetimi, okulun teknoloji yatırımlarının verimliliğini artırarak kurumların dijital olgunluğuna katkı sağlar. Eğitim ortamları hızla dönüşürken, öğretmenlerin bu teknolojik yetkinlikleri geliştirmesi, güvenli, destekleyici ve etkili bir öğrenme ortamı oluşturma yanı sıra sürdürülebilir, etkili ve eşitlikçi öğrenme deneyimleri sunmanın da temel koşullarından biri hâline gelmektedir. Bu durum öğretmenlerin yapay zekâ destekli dijital sınıflarda sahip olması gereken becerilerin önemini göstermektedir.

Eğitimde yapay zekâ entegrasyonun ve dijitalleşmenin mevcut durumunu rakamsal değerlerle ifade etmenin, dünya çapında uygulanan farklı öğretim programları nedeniyle güç olduğu düşünülmektedir. Bununla birlikte, bu sistemlerin günümüzde eğitimin yapısal ve ekonomik açıdan büyük bir bölümünü oluşturduğu açıktır. Öğretim Yönetim Sistemleri (ÖYS) 2016 yılında 5,05 milyar dolardan 2025 yılına kadar 18,44 milyar dolara yükselmiş ve bu süreçte yaklaşık %15,52'lik bileşik yıllık büyüme oranı (CAGR) göstermesi beklenmektedir. Bu durum, dijitalleşmenin eğitim alanındaki ekonomik olarak ne kadar büyük bir ağırlığa sahip olduğunu göstermektedir (Ali vd., 2023). Bu büyüme, örgün eğitim ortamlarında çevrim içi öğrenme platformlarının ve dijital eğitim kaynaklarının küresel ölçekte giderek daha fazla benimsendiğini ortaya koymaktadır.

Bir başka raporda ise dijital eğitim teknolojileri (EdTech) pazarının 2024 yılı itibarıyla 250 milyar doları aşması ve yıllık bileşik büyüme oranının %15 ile %20 arasında olacağı öngörüsü, eğitimin temel altyapı bileşenlerine yapılan yatırımları gözler önüne sermektedir (Grand View Research, 2024). Dünya çapında yaşanan COVID-19 pandemisinin hızlandırdığı dijital dönüşüm sürecinin ardından, öğrenme yönetim sistemleri ve çevrim içi araçlarla desteklenen karma (hibrit) öğrenme modellerinin, yükseköğretim ve K-12 eğitim kurumlarının büyük bir çoğunluğunda (%40–%70) uygulama düzeyine ulaştığı belirtilmektedir (Dziuban vd., 2018; Henríquez & Hilliger, 2024; Mozeliuss & Hettiarachchi, 2017; Organisation for Economic Co-operation and Development (OECD), 2021; United Nations Educational Scientific and Cultural Organization (UNESCO), 2021).

Literatürde yer alan raporlar, öğretim yönetim sistemlerini de kapsayan e-öğrenme ortamlarının 2028 yılına kadar ortalama 375 milyar dolar büyüklüğe ulaşabileceğini ve sürekli olarak bir büyüme eğilimi göstereceğini ileri sürmektedir (Keshavarz & Yuan, 2023). Bu durum, ders materyallerinin ve öğrenci-öğretmen etkileşim süreçlerinin önemli bir bölümünün artık dijital platformlar üzerinden yürütüldüğünü ve dijitalleşmenin eğitim içeriğinin yarısına yakınına etkilediğini göstermektedir. Ayrıca, öğrencilerin günlük yaşamlarında teknolojiye olan yüksek bağımlılıkları dikkate alındığında, eğitim ortamlarının bu dijital talebe yanıt verme zorunluluğu ortaya çıkmaktadır (Türkiye İstatistik Kurumu (TÜİK), 2024). Dijital eğitim ortamları, yalnızca ÖYS'leri değil, uzaktan öğrenmeyi destekleyen çeşitli çevrim içi kaynakları ve teknolojileri de kapsamaktadır (Keshavarz & Yuan, 2023). Bu kapsamda, çevrim içi öğrenme platformları gibi daha geniş e-öğrenme çerçevelerini içeren dijital eğitim araçlarının yaklaşık %35,6'lık bir CAGR sergilemesi beklenmektedir (Dampson, 2021).

Genel dijitalleşmenin bu yaygın ve yüksek oranlı etkisine karşın, yapay zekâ destekli sınıf ortamlarının adaptif öğrenme, otomatik notlandırma veya akıllı rehberlik amaçlı kullanımının, mevcut eğitim süresinin tahmini olarak %5'inden daha azını oluşturduğu belirtilmektedir (Markets & Markets, 2024). Bu düşük kullanım oranı, yapay zekâ teknolojilerinin yeni olması ve eğitim-öğretim kurumlarının altyapı entegrasyonuna ilişkin yaşanan zorluklarla ilişkilendirilebilir. Bu doğrultuda UNESCO, 2023 yılında yayımladığı rehber belgede yapay zekânın eğitime entegrasyonunun önündeki en kritik engelleri altyapı yetersizliği ve öğretmen yeterliliği olarak tespit etmiş; bu engellerin aşılmasıyla birlikte küresel benimseme hızının önemli ölçüde artacağını öngörmüştür (UNESCO, 2023). Bununla birlikte, yapay zekâ teknolojilerinin EdTech pazarı içerisindeki yıllık büyüme oranının %35 ile %45 arasında öngörülmesi, bu payın önümüzdeki yıllarda hızla artacağına ve yapay zekâ destekli dijital sınıf ortamlarının daha çok kullanılan ortamlardan biri hâline geleceğine işaret etmektedir (Markets & Markets, 2024).

K-12 düzeyinde yapılan araştırmalar doğrultusunda, yapay zekâ destekli eğitim teknolojilerinin benimsenmesinin arttığını ve kurumların yaklaşık %20–%30'unun eğitim süreçlerinde bir tür yapay zekâ uygulaması kullandığını göstermektedir (Viberg vd., 2024). Ayrıca, eğitimde yapay zekâ pazarının 2020–2026 yılları arasında yaklaşık %45–%50'lik bir CAGR ile büyümesinin beklendiği ifade edilmektedir (Woodruff vd., 2023). Buna karşılık, Öğrenme Yönetim Sistemleri pazarının 2020–2025 yılları arasında yaklaşık %15'lik bir CAGR ile büyümesinin öngörülmesi, daha yerleşik dijital platformlara kıyasla yapay zekâ temelli teknolojilerin eğitim uygulamalarına daha hızlı entegre edildiğini ortaya koymaktadır (Dampson, 2021).

Bu hızlı dönüşüm beklentisi, öğretmen yeterlikleri açısından önemli bir boşluk yaratmaktadır. Araştırmalar, öğretmenlerin %50'den fazlasının yapay zekâ destekli araçları derslerinde etkin biçimde kullanma konusunda kendilerini yeterli hissetmediğini göstermektedir (Huang & Cheng, 2023). Bu yetersizlik algısı, dijital ortamlarda öğrenci motivasyonu ve katılımına ilişkin sorunların devam etmesine yol açmakta ve yapay zekânın potansiyelinden tam olarak yararlanılmasını engellemektedir (Kuhfeld & Soland, 2020).

Öğretmenler üzerinde yürütülen bir çalışmada, eğitimcilerin önemli bir bölümünün yapay zekâ tabanlı eğitim teknolojilerine güvendiği, fakat yaklaşık %30' unun bu araçları derslerinde kullanma konusunda kendisini yeterli gördüğü belirlenmiştir (Ayanwale vd., 2024). Araştırmanın bu bulgusu, yapay zekâyâ yönelik ilgi ve güven ile fiili kullanım yeterliği arasında belirgin düzey bir fark olduğunu göstermektedir. Bir başka çalışmada ise; öğretmenlerin yapay zekâ okuryazarlık düzeyleri incelenmiş ve öğretmenlerin yaklaşık %40' ının yapay zekâ uygulamalarına ilişkin temel düzeyde bilgiye sahip olduğu ifade edilmiştir. Buna karşın bu uygulamaları eğitim bağlamında etkili biçimde kullanma konusunda öğretmenlerin yeterli düzeyde bilgi sahibi olmadıkları ortaya konmuştur (Ng vd., 2023).

Literatür incelendiğinde öğretmenlerin yaklaşık %40' ının, öğretim uygulamalarında Bilgi ve İletişim Teknolojilerini (BİT) yüksek düzeyde kullandıkları belirtilmiştir. Bu durum, özellikle devlet okullarında, dijital araçların günlük eğitim faaliyetlerine giderek daha fazla entegre edildiğini göstermektedir (Szyszka vd., 2022). Web 2.0 araçlarının kullanımına ilişkin daha ayrıntılı analizler, öğretmenlerin %93,5'inin Canva, %87,1' inin YouTube ve %77,4' ünün eğitim amaçlı WhatsApp kullandığını ortaya koymaktadır. Buna karşılık, eğitim amaçlı podcast'ler ve özel dil öğrenme yazılımlarının kullanım oranlarının daha düşük olduğu belirtilmektedir (Ananda vd., 2025). Ayrıca, öğrencilerin %41,4' e kadarının eğitim faaliyetlerinde Google Classroom kullandığı ve bu durumun öğrenme ortamlarında iş birliğine dayalı dijital platformların yaygınlaştığını gösterdiği ifade edilmektedir (Ananda vd., 2025).

Dijital araçların entegrasyonunda öne çıkan temel engellerden biri, öğretmenler arasında eğitim ve özgüven eksikliğidir. Birçok eğitimci, dijital araçlara belirli ölçüde aşına olmasına rağmen, bu teknolojileri etkili biçimde kullanabilmek için mesleki gelişim ihtiyacı duyduklarını belirtmektedir (Polak vd., 2022; Savov vd., 2017). Yapılan odak grup çalışmaları da öğretmenlerin dijital yetkinliklerine ilişkin özgüvenlerinin, yapay zekâ ve diğer dijital araçları öğretim uygulamalarına entegre etme isteklerinin önemli ölçüde etkilendiğini göstermektedir (Polak vd., 2022). Bu durum, öğretmenlerin dijital ve yapay zekâ temelli yeterliklerinin güçlendirilmesinin, sınıflarda teknolojinin etkin kullanımını artırmada kritik bir rol oynadığını ortaya koymaktadır.

Bilgi ve iletişim teknolojilerinin (BİT) eğitime entegrasyonu, geleneksel sınıfların dijital öğrenme ortamlarına dönüştürülmesinde çok önemli bir rolü olduğu söylenebilir. Yapılan araştırmalardan da anlaşılacağı üzere günümüzde öğrenme yönetim sistemleri, sanal sınıflar ve yapay zekâ uygulamaları gibi dijital araçların eğitim- öğretim süreçlerinde kullanımında bir artış görülmektedir. Bunun nedeni olarak yapılan araştırmalarda, teknolojik araçlar sayesinde bireyselleştirilmiş öğrenmenin ve her öğrenci profiline uygun pedagojik uygulamaların kullanımının kolaylaştığı belirtilmektedir (Avedzi, 2025).

Dijital öğrenme ortamları, geleneksel sınıflara kıyasla öğrenme analitiği ve veri toplamayı önemli ölçüde kolaylaştırmakta; gerçek zamanlı ölçme-değerlendirme imkânı sunmaktadır (Papamitsiou & Economides, 2014; Romero & Ventura, 2020; Siemens & Long, 2011; Yalçın & Demir, 2018). Bu sayede öğrencilerin performansları hızlı biçimde analiz edilmekte ve geri bildirim süreçleri daha etkin yürütülebilmektedir (Ifenthaler & Yau, 2020; Nasir vd., 2024; Wang vd., 2024).

Dijitalleşme ile ortaya çıkan yapay zekânın dijital sınıf ortamlarına entegrasyonu, öğretmenlerin idari ve değerlendirme yüklerini azaltarak sınıf yönetiminde önemli dönüşümlere zemin hazırlamıştır (Li, 2024). Öğrenme analitiği, öğrenci takibi, geri bildirim ve içerik yönlendirmesi gibi süreçler yapay zekâ entegrasyonu ile daha etkili biçimde yürütülebilmektedir (Lin vd., 2023; Lopez-Meneses vd., 2025; Milli Eğitim Bakanlığı Yenilik ve Eğitim Teknolojileri (MEB Yeğitek, 2025); Rodriguez-Ortiz, 2025; Sajja vd., 2023; Wang vd., 2024).

Yapay zekâ destekli sınıf ortamlarında öğretmenlerin veri okuryazarlığı, öğrenme analitiği verilerini yorumlama ve bireyselleştirilmiş öğretim kararları alma becerilerine sahip olması gerekmektedir (Davids vd., 2025; Li, 2025; Mandinach & Gummer, 2016; Schildkamp & Poortman, 2015). Öğretmenlerin yalnızca dijital araçları kullanabilmeleri değil, bu araçlardan elde edilen verileri pedagojik karar alma süreçlerine entegre edebilmeleri etkili öğretmen yeterliliğinin temel unsurlarından biri hâline gelmiştir (Chatti vd., 2020; Romero & Ventura, 2024).

Yapay zekâ destekli dijital sınıflarda öğretmenlerin veri gizliliği, etik kullanım ve algoritmik önyargı konularında bilgi sahibi olmaları gerekmektedir. Yapay zekâ sistemlerinin geçmiş verilere dayalı çalışması, mevcut toplumsal önyargıları yeniden üretebilme riskini barındırmaktadır (Barocas vd., 2019; Holstein vd., 2019; Jobin vd., 2019). Bu nedenle öğretmenlerin yapay zekâ araçlarını eleştirel biçimde değerlendirebilmeleri ve adalet ile kapsayıcılığı gözetmeleri önemlidir (Dignum, 2019; Floridi & Cowls, 2019; Williamson & Eynon, 2020).

1.1. Araştırmanın Amacı

Eğitim- öğretimde dijital ve yapay zekâ destekli sınıf ortamlarına yönelik yurt içi ve yurt dışı geliştirilen ölçme araçları incelendiğinde, bu ölçme araçlarının genellikle öğretmenlerin yapay zekâ öz-yeterlik algılarını, dijital yeterliklerini, tutumlarını ve dijital/ yapay zekâ okuryazarlık düzeylerini ölçmeye yönelik olduğu görülmektedir (Atun & Usta, 2019; Ayanwale vd., 2023). Bu ölçekler, öğretmenlerin yapay zekâ ve dijital teknolojilere ilişkin bilişsel ve duyuşsal hazırbulunuşluk düzeylerini belirlemede güçlü bir ölçme yapabilirken, yapılan ölçümlerin genel olarak öz-bildirime dayanması nedeniyle, bu öğretmenlerin sahip olması gereken yeterliliklerin sınıf yönetimi uygulamalarına ve öğretmen-öğrenci etkileşimine nasıl yansıdığını ölçmede yetersizdir. Uluslararası alanyazınında yapay zekâ ve dijital okuryazarlık ölçekleri ise öğretmenlerin bu alandaki teknik bilgi, uygulama ve etik gibi boyutlarıyla değerlendirmektedir (Carolus vd., 2023; Laupichler vd., 2023; Ng vd., 2024; Soto-Sanfiel vd., 2025; Sun, 2025; UNESCO, 2024; Viberg vd., 2023; Wang vd., 2023). Bunun yanı sıra, MAILS, AILS/AILQ, SNAIL, MAIL-CS ve SAIL4ALL gibi bu alanda en kapsamlı olarak görülen yapay zekâ okuryazarlığı ölçekleri, öğretmenlerin bu alandaki yeterliliklerini genellikle bireysel bilgi ve farkındalık düzeyinde değerlendirirken; yapay zekâ destekli ya da dijital sınıf yönetiminin pedagojik karar alma, sınıf içi etkileşim ve öğrenme deneyimi üzerindeki etkilerini doğrudan ölçmemektedir (Carolus vd., 2023; Laupichler vd., 2023; Ng vd., 2024). Aynı şekilde, dijital yeterlilik alanındaki ölçme araçları, teknoloji kullanabilme becerilerini ve teknik yeterlikleri belirlemede yeterli olsa bile, yapay zekâ destekli sınıf ortamlarında olması gereken etik sorumluluklar, veri temelli eğitim-öğretim kararları ve veriye dayalı (algoritmik) yönlendirmelerin sınıf yönetimine etkisini bütüncül olarak değerlendirmekte yetersiz kalmaktadır (Calvani vd., 2012; Kim vd., 2022). Can & Gündüz (2021) tarafından yapılan dijital sınıf yönetimi çalışması da genel dijital sınıf yönetimi alanında yeterlilikler için güvenilir sonuçlar sunabilirken; günümüzde ise dijital sınıflara yapay zekânın entegre edilmesiyle ölçek bu alanı ölçmede yetersiz kalmaktadır.

Sonuç olarak mevcut durumdaki ölçme araçlarının dijital alanda ve yapay zekâ alanında belirli yeterlikleri ölçbildiği bilinmektedir. Ancak öğretmenlerin yapay zekâ destekli dijital sınıf ortamlarında sahip olduğu yeterlilikleri doğrudan sınıf yönetimi bağlamında ele alan ve bu durumu öğrenciler tarafından, öğretmenlerin değerlendirildiği bir ölçme aracı bulunmamaktadır. Çünkü yapay zekâ destekli sınıf yönetiminde dijital yeterliklerin yanı sıra veri temelli kararlar alma, öğrenme analitiklerini yorumlayabilme, etik sorumluluklar vb. alanlarda yeterliklere sahip olunması gerekmektedir. Bu alanda öğrencilerin görüşünün alınması öğretmenlerin sahip oldukları yeterlikleri sınıf ortamlarında ne düzeyde uyguladıklarını ortaya çıkarabilecektir. Son zamanlarda gelişen bu alanda yeni ve özgün ölçme araçlarına ihtiyacın olduğu görülmektedir. Bu sebeple bu ölçek geliştirme çalışmasına ihtiyaç duyulmuştur.

1.2. Araştırmanın Önemi

Dijital araçlar ve platformlar, geleneksel sınıf ortamlarına göre öğrenme analitiği ve veri toplamayı önemli ölçüde kolaylaştırmıştır (Papamitsiou & Economides, 2014; Siemens & Long, 2011). Bu sayede elde edilen veriler ile öğrenciler için bireyselleştirilmiş öğrenme yöntemlerine ve geri dönütlere imkânlar sağlamıştır (Ifenthaler vd., 2019). Çünkü geleneksel sınıf ortamında ölçme-değerlendirmeler daha sınırlıyken dijital öğrenme ortamında ölçme-değerlendirme yöntemleri ile gerçek zamanlı veriler toplanabilmektedir (Romero & Ventura, 2020).

Aynı zamanda bu sistemler sayesinde ölçme-değerlendirmelerin hızlıca sonuçlandırılması ve öğrencilerin performansları hakkında geri dönütleri daha hızlı bir şekilde alabilmeleri mümkündür (Nasir vd., 2024; Wang vd., 2024). Öğrenme yönetim sistemlerinde kullanılan öğrenme analitiği araçları, öğrenci etkinliklerini, etkileşimlerini ve performanslarını anlık takip edebilmektedir. Bu araçlar sayesinde öğretim metotlarının seçilebilmesi ve öğrenci yönlendirilmesinin yapılabilmesinde, öğrenci ihtiyaçları dikkate alınabilmektedir (Andhika vd., 2024; Mwalumbwe & Mteb, 2017).

Dijital sınıf yönetiminin amacının, geleneksel sınıf yönetim modelleri gibi sadece öğrencilerin sınıf içi davranış kurallarını belirlemek olmadığı; öğrencilerin eğitim-öğretim süreçlerini geliştirmek ve iyileştirmek için teknolojinin sunduğu fırsatlardan faydalanmayı içerdiği belirtilmektedir (Begum, 2024; Jian, 2023). Bu bağlamda dijital sınıf ortamları, gerçek zamanlı veriler ve analizler, derse katılım ve devam oranlarının takibi, öğrencilerin ders materyalleri ile etkileşim kurup kurmadığının izlenmesi ve öğrencilerin zorlandığı içerik alanlarının belirlenmesi gibi olanaklar sunmaktadır (Gharbaoui vd., 2023; Krishnan vd., 2022).

Dijitalleşme ile ortaya çıkan yapay zekânın dijital sınıf ortamlarına entegrasyonu, öğretmenlerin idari ve değerlendirme yüklerini azaltma, öğrenci davranışlarını tahmin edebilme ve bireyselleştirilmiş eğitim uygulamalarına zemin hazırlamıştır. Yapay zekâ, eğitim-öğretim süreçlerini otomatikleştirerek ve bireyselleştirerek dijital sınıf ortamlarında yönetimi sağlamada önemli bir araç olarak değerlendirilmektedir (Li, 2024). Öğrenme analitiği, öğrenci takibi, geri dönütler ve içerik yönlendirmesi yapay zekâ entegrasyonu ile daha başarılı bir şekilde gerçekleştirilebilmektedir (Akçapınar, 2024; Lin vd., 2023; Lopez-Meneses vd., 2025; MEB Yeğitek, 2025; Rodriguez-Ortiz, 2025; Sajja vd., 2023; Topali vd., 2024; Wang vd., 2024).

Yapay zekâ destekli dijital sınıf ortamlarında öğrencilerin davranış biçimleri analiz edilerek öğretmenlerin önlemler (proaktif) davranmasına ve öğrencilere yönelik destek çalışmalarını öğrencilerin ihtiyaç ve gereksinimlerine göre uyarlamalarına olanak sağlanmaktadır (Badawy vd., 2024; Gomez vd., 2025; Zhan ve Cui, 2023). Öngörücü algoritmalar, öğrencilerin ders katılım ve performans ölçümlerini dikkate alarak risk altında olan öğrencileri belirleyebilmekte ve öğretmenlerin bu öğrenciler için bireyselleştirilmiş ve anında geri dönütler sunmasına imkân tanımaktadır (Almuqhim & Berri, 2025; Zhou, 2024).

Yapay zekâ destekli sınıf ortamlarında kullanılan araçların, öğrencilerin ödev kontrollerini ve notlandırılmasını kolaylaştırarak öğretmenlerin iş yüklerini ve derslerde yaşanan zaman kayıplarını azalttığı ifade edilmektedir (Ragolane vd., 2024). Yapay zekâ ve dijital araçlarla oluşturulan sınıf ortamları, öğretmenlerin sezgisel kararlar yerine veri analitiğine dayalı, daha nesnel ve kanıta dayalı kararlar almasına olanak sağlamaktadır (Meylani, 2024; Ndal, 2025; Sajja vd., 2025).

Yapay zekâ destekli dijital sınıflarda öğretmenlerin veri okuryazarlığı, yapay zekânın etik kullanımı, algoritmik önyargı farkındalığı, pedagojik alan bilgisi ve yapay zekâ araçlarını kullanma becerilerine sahip olması gerektiği vurgulanmaktadır. Veri okuryazarlığı, yapay zekâ platformlarından elde edilen verilerin yorumlanması, öğrencilerin performans eğilimlerinin fark edilmesi ve bu verilerin öğretim stratejilerini bireyselleştirmek için kullanılması anlamına gelmektedir (Davids vd., 2025; Echtenbruck vd., 2025). Öğretmenlerin yalnızca verileri analiz etmeyi değil, bu veriler ışığında öğrencilerin öğrenme çıktılarını düzenleyen kararlar alabilmeleri gerektiği belirtilmektedir (Mandinach & Gummer, 2016; Schildkamp & Poortman, 2015).

Yapay zekâ destekli sınıflarda öğretmenlerden beklenen bir diğer önemli beceri, yapay zekânın etik kullanımıdır. Öğretmenlerin algoritmik önyargıların farkında olmaları, veri gizliliği, adalet ve şeffaflık ilkelerini gözetmeleri gerektiği vurgulanmaktadır (Dignum, 2019; Floridi & Cowls, 2019; Jobin vd., 2019; Williamson & Eynon, 2020). Ayrıca öğretmenlerin, yapay zekâ sistemlerinin sunduğu önerileri eleştirel biçimde değerlendirmeleri ve bu önerileri pedagojik yargı ve mesleki uzmanlıkla dengelemeleri gerektiği ifade edilmektedir (Barocas vd., 2019; Holstein vd., 2019).

Sonuç olarak, yapay zekâ destekli dijital sınıf ortamlarında öğretmenlerin veri okuryazarlığı, etik farkındalık, öğrenme analitiğine dayalı karar alma, bireyselleştirilmiş öğretim ve otomatik geri dönüt sistemlerini etkili biçimde kullanma becerilerine sahip olmalarının, sınıf yönetiminin etkililiğini artırdığı

belirtilmektedir. Bu nedenle günümüzde bu becerileri ölçebilecek bir ölçeğe ihtiyaç giderek arttığı görülmektedir. Geliştirilen bu ölçek bu alanda geçerli ve güvenilir bir ölçeğe aracı olması nedeniyle önemlidir.

2. YÖNTEM

Araştırmanın bu bölümünde, yöntem olarak ölçek geliştirme basamakları dikkate alınmıştır. Bu süreçler aşağıda detaylı bir şekilde ifade edilmiştir.

2.1. Araştırmanın Çalışma Grubu

Yapay Zekâ Destekli Sınıf Yönetim Ölçeği'nin çalışma grubu 2024-2025 eğitim- öğretim yılında resmi ve özel okullarda öğrenim gören ve mevcut eğitim-öğretim yılında çevrim içi platformlarda çeşitli derslere katılmış öğrencilerden oluşmuştur. Geliştirilen YZDSY Ölçeğinin geçerlik ve güvenilirlik analizlerini yapmak için ölçüt örnekleme yöntemi kullanılmıştır. Ölçüt örnekleme yöntemi bir deneyimi daha önceden yaşamış, tecrübe etmiş ve belirli bir düzeyde yeterliğe sahip olan kişilerin görüşlerini incelemek için kullanılan bir yöntemdir. (Creswell, 2013; Yıldırım & Şimşek, 2018). Devellis (2017) ve Kline'e (2014) göre bir ölçek geliştirme çalışmasında örneklem büyüklüğü belirlenirken örneklem büyüklüğünün en az madde sayısının 5 katı tercihen 10 katı olması gerekmektedir. Örneklem büyüklüğü için Tabachnick & Fidell (2013) ise minimum 150 katılımcının çalışma grubuna dâhil edilmesi gerektiğini belirtmektedir. Bu bağlamda geliştirilen YZDSY Ölçeğinin 35 maddesinin var olduğu dikkate alınarak çalışma grubuna 486 öğrenci dâhil edilmiştir. Ölçek geliştirme çalışmalarında gerçekleştirilmesi gereken açılımlı faktör analizi için örneklem büyüklüğünün en az 300 kişi olması, ayrıca örneklem faktör yapısını güvenilir biçimde temsil etmesi gerekmektedir (Fabrigar vd., 1999; Tabachnick & Fidell, 2015). Bu çalışmada oluşturulan çalışma grubu söz konusu ölçütleri karşılamaktadır.

Geçerlik ve güvenilirlik analizleri kapsamında gerçekleştirilen AFA ve DFA için aynı nitelikte farklı çalışma grupları oluşturulmuştur. Araştırmanın AFA süreci 239, DFA süreci 247 öğrencinin katılımıyla oluşturulan, çalışma gruplarıyla yürütülmüştür.

2.2. Veri Toplama Araçları ve Süreci

Taslak ölçeğin geliştirilmesinde madde havuzu oluşturma, uzman görüşü alma ve ön uygulama gerçekleştirme aşamaları yürütülmüştür.

2.2.1. Madde Havuzu Oluşturma

Yapay Zekâ Destekli Sınıf Yönetimi Ölçeği'nin (YZDSYÖ) geliştirilme sürecinde ölçeğin madde havuzu oluşturulurken öncelikle ölçülmek istenen yapının kuramsal çerçevesi ayrıntılı bir şekilde incelenmiştir. Bu kapsamda ilgili alanyazını üzerinde sistematik taramalar yapılmış, ölçeğin dayandığı kuramsal yaklaşım (Ng vd., 2024; UNESCO, 2024; Wang vd., 2023) benzer yapıyı ölçen ölçekler (MAILS, AILQ, SNAIL) (Can & Ertuğ, 2021; Carolus vd., 2023; Laupichler vd., 2023; Wang vd., 2023) ve konuya ilişkin gerçekleştirilen farklı çalışmaların ortaya koyduğu bulgular dikkate alınmıştır. Ölçek geliştirme çalışmalarında taslak ölçeğin kuramsal bilgi zemininde oluşturulması, ölçeğin gelecekte farklı öngörülere sahip ve yeniden gözden geçirilebilir olmasını sağlar (Devellis, 2017; Navarro, 2020). Bu kapsamda ölçülmek istenen yapının bileşenleri belirlenmiş ve her bir boyutu temsil edecek şekilde taslak maddeler yazılmıştır. Madde yazım sürecinde maddenin tek bir davranış, tutum ya da yargıyı ölçmesine, açık ve anlaşılır bir dille ifade edilmesine, çift anlamlılıktan kaçınılmasına özen gösterilmiştir. Ayrıca maddelerin belirlenen hedef kitleye yaş, bilişsel düzey, sosyo- kültürel özellikler açısından uygunluğu gözetilmiştir (Boateng vd., 2018). Bu süreç sonucunda 30 maddeden oluşan taslak madde havuzu oluşturulmuştur. Bu tür çalışmalarda başlangıçtan hedeflenen daha fazla madde yazılması ileride yapılacak elemeler için kolaylık sağlayabilmektedir (Devellis, 2017; Worthington & Whittaker, 2006).

2.2.2. Uzman Görüşü

Oluşturulan taslak madde havuzu ölçme aracının kapsam ve görünüş geçerliğini sağlamak için alanında uzman akademisyenlerin değerlendirilmesine sunulmuştur. Devellis'e (2017) göre, ölçek geliştirme çalışmalarında uzman görüşüne başvurmak maddelerin ölçülmek istenen yapıyı temsil yeterliğini belirlemede temel bir aşamadır. Bu doğrultuda hazırlanan taslak ölçek formu toplam 5 akademisyenin görüşüne sunulmuştur. Uzmanlardan her bir maddeyi "tamamen uygun", "uygun", "kısmen uygun", "uygun değil" biçiminde değerlendirmesi istenmiştir. Uzman değerlendirmeleri arasındaki uyumun düzeyini belirlemek amacıyla Kendall's uyum katsayısı hesaplanmıştır (Kendall's W= .440). Kendall's katsayısı birden fazla uzmanın aynı maddelere ilişkin derecelendirmelerinin istatistiksel olarak anlamlı düzeyde benzerlik olup olmadığını tespit etmektedir. Uzmanlardan gelen geri bildirimler doğrultusunda bazı maddelerde ifadeler sadeleştirilmiş, kavramsal olarak netleştirilmiş ve hedef kitleye uygunluk açısından çeşitli düzenlemeler yapılmıştır. Bu süreç sonunda uzman görüşüne gönderilen 30 maddeden oluşan taslak form 28 maddeye düşürülmüştür. Bu işlemin ardından YZDSY Ölçeğinin ön uygulama aşamasına geçilmiştir.

2.2.3. Ön Uygulama

Uzman görüşleri ve gerekli düzenlemeler sonucunda elde edilen 28 maddelik ön uygulama formu, asıl uygulama öncesinde maddelerin anlaşılabilirliğini, uygulanabilirliğini, yanıtlanabilirliğini ve ölçeğin ön güvenilirliğini test etmek amacıyla 39 kişilik bir pilot çalışma grubuna uygulanmıştır. Pilot uygulamaların, ölçek geliştirme sürecinde maddelerin hedef kitle tarafından doğru algılanıp algılanmadığını belirlemede kritik bir aşama olarak kabul edilmektedir (DeVellis, 2017; Hinkin, 1998). Ön uygulama grubunun, ölçeğin hedef kitlesini temsil edecek özelliklere sahip bireylerden seçilmesine dikkat edilmiştir. Pilot uygulama sürecinde katılımcılardan yalnızca maddeleri yanıtlamaları değil, aynı zamanda anlaşılmayan, karmaşık bulunan veya tereddüt yaratan ifadeler hakkında geri bildirim vermeleri de istenmiştir. Bu geri bildirimler doğrultusunda bazı maddelerde ifade sadeleştirilmesi, dil düzeltmesi ve kavramsal netleştirme yapılmıştır. Daha sonrasında ölçeğin nihai uygulamaya uygun olduğu görülmüş ve gerekli görülen son düzeltmeler yapılarak ölçek faktör analizi aşamasına hazır hâle getirilmiştir.

Bunun yanı sıra taslak ölçek formunda yer alan maddelerin ne kadar anlaşıldığının belirlenmesi için 21 öğrenciden oluşan ayrı bir çalışma grubu belirlenmiştir. Ayrıca 18 öğrencinin katılımıyla oluşturulan farklı bir çalışma grubuyla ölçeğin ortalama cevaplama süresi tespit edilmiştir. Ölçek katılımcılar tarafından ortalama 10 dakikada cevaplandırılmıştır.

2.3. Verilerin Analizi

Ölçeğin geçerlik ve güvenilirlik analizleri gerçekleştirilmeden önce elde edilen veriler eksik veri, uç değer ve normallik varsayımı açısından incelenmiştir. Uç değerlerin hesaplanmasında Z puanı dikkate alınmış ve -3 ile +3 aralığında yer almayan veriler uç değer olarak nitelendirilmiştir. Normallik değerlendirmesinde çarpıklık ve basıklık değerlerin -2 ile +2 değerleri arasında kaldığı görülmüştür. Bu durum verilerin çok değişkenli analizler için uygun olduğunu göstermiştir (Tabachnick & Fidell, 2013).

YZDSY Ölçeğinin faktör yapısını belirlemek için ilk olarak açımlayıcı faktör analizi (AFA) uygulanmıştır. Araştırma verilerinin faktör analizine uygun olduğunu tespit etmek için Kaiser-Meyer- Olkin (KMO) katsayısı ve Bartlett Küresellik Testi uygulanmıştır. KMO değerinin 0,60'ın üzerinde olması ve Bartlett testinin $p < 0.05$ düzeyinde anlamlı olması gerekmektedir (Büyüköztürk, 2023). KMO değeri ve Bartlett küresellik testinin yanı sıra verinin faktör analizine uygunluğunun değerlendirilmesi için Anti-İmaj korelasyon matrisi incelenmelidir. Matrisde yer alan anti-ımağ köşegen değerleri her bir maddenin faktör analizine uygunluğunu belirlemek amacıyla kullanılır. Bir maddenin faktör analizine uygun olduğunun belirlenmesi için elde edilen anti-ımağ köşegen değeri ,50 üzerinde olmalıdır. Bu değer (<,50) altında olan maddeler ölçekten çıkarılmalıdır (Hair vd., 2019). Yapılan analizler sonucunda elde edilen anti-ımağ köşegen değerlerinin tamamı ,50'den büyüktür. YZDSY ölçeğine ait veriler faktör analizine uygun olduğunu göstermektedir.

Faktör analizinde temel bileşenler analizi (Principal Components Analysis) kullanılmıştır. Faktörlerin yorumlanabilirliğini artırmak için Varimax dik döndürme tekniği tercih edilmiştir. Kaiser (1974), Varimax döndürme tekniğinin, faktör yapısını basitleştirerek her bir faktörün ayırt ediciliğini güçlendirdiğini ve bu nedenle ölçme araçlarının yapı geçerliğini kuvvetlendirdiğini belirtmiştir. AFA sürecinde faktör yüklerinin 0,40 ve üzerinde olması ölçüt olarak alınmıştır. Birden fazla faktöre yüklenen maddeler çıkarılarak (Hair vd., 2014), ölçeğe 3 faktörlü 28 maddelik bir yapı kazandırılmıştır. AFA sonucunda elde edilen faktör yapısının doğrulanması için doğrulayıcı faktör analizi (DFA) uygulanmıştır. Doğrulayıcı faktör analizi (DFA) ölçeğin kuramsal olarak belirlenen faktör yapısının veriyle ne ölçüde uyum sağladığını test etmek amacıyla uygulanmıştır. DFA teorik olarak öne sürülen bir faktör modelinin gözlemlenen verilerle uyumunu değerlendiren bir yapısal eşitlik modelleme tekniğidir (Brown, 2015). Bu analizde AFA sonucu elde edilen 3 faktörlü yapı test edilecek hipotez model olarak temel alınmıştır. Analizin güvenilirliği için örneklem büyüklüğünün yeterliği Kline'nın (2016) her faktör için en az 5 ile 10 katılımcı önerisi referans alınarak kontrol edilmiştir. Ardından kullanılacak veri setinin faktör analizi için uygunluğu KMO değeri ve Bartlett Küresellik testi ile doğrulanmıştır.

DFA ile elde edilen modelin uyum iyiliği χ^2/df , RMSEA, CFI, GFI, NFI, IFI indeksleri kullanılarak değerlendirilmiştir (Hu & Bentler, 1999; Kline, 2016). Gerçekleştirilen DFA sonrası oluşan yapı ikinci düzey DFA ile yeniden sınanmıştır. Kullanılan uyum ölçütleri ve yorumlama için eşik değerleri Hu & Bentler (1999) ile Schreiber (2021) tarafından önerilen standartlara göre belirlenmiştir. Bu çerçevede χ^2/df oranının 5'in altında olması kabul edilebilir, 3'ün altında olması ise iyi uyum göstergesidir. RMSEA değerinin ise ,08'in altında olması makul bir uyumu ,05'in altında olması ise mükemmel bir uyumu göstermektedir (Steiger, 2007). Ek olarak CFI, AGFI, GFI ve IFI ,80'den büyük olması modelin kabul edilebilir düzeyde uyum sağladığını göstermektedir (Byrne, 1998; Kline, 2016).

AFA ve DFA sonucunda elde edilen yapının iç tutarlığı Cronbach Alpha, Mc'Donalds Omega ve AVE katsayıları ile hesaplanmıştır. Bu katsayılardan Cronbach Alpha ve Mc'Donalds Omega'nın ,70 üzerinde olması ve AVE katsayısının ,50'nin üzerinde olması iç tutarlık açısından yeterli kabul edilmiştir. Bu veriler AFA önkoşul varsayımını sağlamaktadır (Nunnally ve Bernstein, 1994). Ayrıca maddenin ayırt edicilik düzeyini belirlemek için madde toplam korelasyonları ve üst- alt grup t değerleri hesaplanmıştır. Madde toplam korelasyonuyla elde edilen değerin ,30 ve üzerinde olması bir kriter olarak kabul edilmiştir (Büyüköztürk, 2023).

2.4. Araştırmanın Etik İzni

Yapılan bu çalışmada "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.

Etik kurul izin bilgileri

Etik değerlendirmeyi yapan kurul adı: Necmettin Erbakan Üniversitesi Etik Kurulu

Etik değerlendirme kararının tarihi: 10.01.2025

Etik değerlendirme belgesi sayı numarası: 2025/02


3. BULGULAR

Çalışmanın bu kısmında ilk olarak yapı geçerliğine ilişkin gerçekleştirilen analizler raporlanmıştır. Bu işlemin ardından ölçeğin güvenirlik analizlerine ilişkin bulgular sunulmuştur.

3.1.1. Yapı Geçerliğine İlişkin Bulgular

Yapay Zekâ Destekli Sınıf Yönetimi Ölçeği'nin geliştirilme sürecinde ölçekten elde edilen faktör yapısı açımlayıcı faktör analiziyle (AFA) belirlenmiştir. Costello & Osborne' a (2005) göre bir ölçeğin yapı geçerliğini sağlamak amacıyla ölçeği oluşturan alt boyutların keşfedilmesi ve maddelerin bu boyutlardaki faktör yüklerinin değerlendirilmesi için AFA tekniği kullanılmalıdır. Çalışma kapsamında toplanan verilerin faktör analizi için uygunluğu Kaiser-Meyer-Olkin (KMO) örneklem yeterliliği testi ve Bartlett Küresellik Testi kullanılarak test edilmiştir. Elde edilen sonuçlara göre KMO değeri ,907 olarak belirlenmiştir. Bartlett Küresellik testi sonucu elde edilen ki-kare değeri istatistiksel açıdan anlamlı bulunmuştur ($\chi^2=1792,974$; $p<0.001$). Tabashnick & Fidell (2019), KMO değerinin ,60 üzerinde olması ve Bartlett Küresellik testi sonucunun istatistiksel açıdan anlamlı olması faktör analizleri için yeterlidir. Tüm bu bulgular YZDSYÖ'nün verilerini faktör analizi gerçekleştirmek için uygun olduğunu göstermektedir.

Ölçek geliştirme çalışmalarında yapılacak faktör analizinde, temel bileşenler analizi (Principal Component Analysis) ve temel eksen faktörleştirme analizi (Principal Axis Factoring) gibi yöntemler tercih edilebilir (Horn, 1965). YZDSYÖ'nün faktör yapısını belirlemek amacıyla temel bileşenler analizi (Principal Component Analysis) tercih edilmiştir. Elde edilen faktörlere ait öz değerlerin 1'in üzerinde olması ve toplam varyans oranı dikkate alınmıştır. Bunun yanı sıra ölçeğe ait faktör yapısı Yamaç Birikinti Grafiği ile belirlenmiştir.



Şekil 1. Ölçeğe ait yamaç birikinti grafiği

YZDSYÖ'nün AFA sonuçları, Yamaç Birikinti Grafiği (Şekil 1) ile incelenmiştir. Elde edilen grafik dikkate alındığında eğimin kaybolduğu noktanın X eksenine göre karşılık geldiği bileşen sayısının üç olduğu görülmüştür. Yamaç birikinti grafiğinden elde edilen bu sonuca göre YZDSYÖ için yeterli faktör sayısı üç olarak kabul edilmiştir.

Faktör yüklerinin yorumlanabilir olması için maddelerin faktör yük değerlerinin ,30'un üzerinde olması ve maddeler arasında yüksek korelasyon bulunmaması gerekir (Field, 2018). Ayrıca maddelerin tek bir faktör üzerinde yüksek yük değeri göstermesi ve çapraz yüklemenin ,32'nin altında kalması temel bir kriter olarak benimsenmiştir (Worthington & Whittaker, 2006). Buna göre YZDSYÖ'ye ait faktör yükleri incelenmiştir. Faktör yükü ,30'un altında olan maddelerle birden çok faktöre yüklenmiş maddeler (M1, M8, M24) uzman görüşü alınarak çıkartılarak analizler yeniden yapılmıştır. Maddelerin çıkartılma sürecinde uzmanların maddeler hakkında verdikleri görüşler dikkate alınmıştır (Bkz. Tablo 1).

Tablo 1. Çıkarılan Maddelere Ait Uzman Görüşleri

Madde No	Uzman Görüşü	Faktör Yüğü	Karar
M8	Benzer yapıyı ölçen başka maddeler bulunmaktadır.	,32-,36	Duplikasyon gösteren maddeler + Uzman görüşü doğrultusunda kapsam ve yapı geçerliğı bozulmuyor
M24	Maddenin kapsam geçerliğı yeterli değildir.	,38-,401	Duplikasyon gösteren maddeler + Uzman görüşü doğrultusunda kapsam ve yapı geçerliğı bozulmuyor
M1	Benzer yapıyı ölçen başka madde bulunmaktadır.	,392-,413	Duplikasyon gösteren maddeler + Uzman görüşü doğrultusunda kapsam ve yapı geçerliğı bozulmuyor

YZDSYÖ'nün 28 maddesinin 3 tanesi yapılan analizler ve uzman görüşü doğrultusunda çıkartılarak 25 maddelik bir yapı elde edilmiştir. Çıkarılan her bir maddenin ardından AFA süreci baştan tekrar yapılmıştır. Elde edilen bulgulara göre 25 maddelik yapının toplam varyansın %58,186'sını açıkladığı görülmüştür. YZDSYÖ'ye ait 3 faktörlü yapının maddelerinin faktör yükleri Tablo 2'de verilmiştir.

Tablo 2. YZDSYÖ'nün Döndürülmüş Bileşenler Matrisi

Faktörler	1	2	3
M16	,842		
M4	,836		
M7	,773		
M12	,771		
M3	,765		
M15	,762		
M21	,720		
M5		,696	
M2		,664	
M20		,660	
M11		,647	
M14		,641	
M17		,639	
M22		,630	
M8		,606	
M24		,532	
M10			,710
M9			,689
M19			,653
M18			,616
M23			,558
M1			,522
M25			,514
M6			,503
M13			,477
Toplam Varyans: %58,18 ; Faktör 1: %22,24, Faktör 2: %20,24; Faktör 3: %15,69			

Tablo 2 incelendiğinde ölçeğe ait maddelerin faktör yüklerinin ,477 ile ,842 arasında değiştiği görülmektedir. Yapılan analizler sonucunda ortaya çıkan faktör yük değerlerinin istenilen yapıyı ölçtüğünü göstermektedir. YZDSYÖ'ye ait 3 faktörlü yapının bileşenlerinin isimlendirilmesinde yapay zekâ destekli sınıf yönetimi ve dijital sınıf yönetimi literatürü dikkate alınmıştır. YZDSYÖ'nün birinci faktörü M16, M4, M7, M12, M3, M15, M21 nolu maddelerden oluşmaktadır. Madde ifadeleri de dikkate alınarak bu faktör Yapay Zekâ Entegrasyonu olarak isimlendirilmiştir. Ölçeğin ikinci faktörü M5, M2, M20, M11, M14, M17, M22, M8 ve M24 nolu maddelerden oluşmaktadır. Bu faktör Dijital Etkileşim olarak adlandırılmıştır. YZDSYÖ'nün üçüncü faktörü M10, M9, M19, M18, M23, M1, M25, M6, M13 numaralı maddelerden oluşmuştur ve Teknopedagojik Altyapı olarak ifade edilmiştir. YZDSYÖ'den elde edilen 3 faktör arasındaki korelasyonların pozitif yönlü ve istatistiksel olarak anlamlı olduğu tespit edilmiştir. Hair vd. (2019) tarafından önerilen faktörler arası korelasyon katsayılarının ,70'in altında olması kriteri dikkate alınmıştır. Bu durum ölçeği oluşturan bileşenlerin birbirinden yeteri kadar ayrıştığını ve ölçeğin yapı geçerliğinin desteklendiğini ortaya koymaktadır. (Bkz. Tablo 3).

Tablo 3. Faktörler Arası Korelasyon Katsayıları

	Yapay Zekâ Entegrasyonu	Dijital Etkileşim	Teknopedagojik Altyapı
Yapay Zekâ Entegrasyonu	1	,554**	,498**
Dijital Etkileşim	,554**	1	,707**
Teknopedagojik Altyapı	,498**	,707**	1

** p<0,01

AFA ile sınanan yapının doğrulanması amacıyla Kline (2015) tarafından da belirtildiği gibi ölçek geliştirme sürecinde doğrulayıcı faktör analizi (DFA) gerçekleştirilmelidir. Bu kapsamda AFA sonucunda ortaya çıkan 3 faktörlü ve 25 maddelik YZDSYÖ doğrulayıcı faktör analizi ile test edilmiştir.


3.1.2. Doğrulayıcı Faktör Analizi

YZDSYÖ için gerçekleştirilen açımlayıcı faktör analizi sonunda ortaya konan 25 maddelik yapı DFA ile yeniden test edilmiştir. Analiz sürecinde M7, M9, M14 numaralı maddelerin hata varyanslarının yüksek, regresyon ağırlıklarının düşük olduğu tespit edilmiştir. Bundan dolayı modelin iyileştirilebilmesi için bahsedilen maddeler çıkarılmış ve analizler yeniden gerçekleştirilmiştir. Bu maddelerin çıkarılması ile ölçeğin kapsam geçerliğinin etkilenip etkilenmediği alan uzmanlarından alınan görüşlere göre değerlendirilmiştir. Uzmanların görüşüne göre maddelerin çıkartılması kapsamı daraltmamaktadır. (Bkz. Tablo 4).

Tablo 4. Doğrulamalı Faktör Analizi Sonucu Çıkarılan Maddeler ve Uzman Görüşü

Madde No	Uzman Görüşü	Madde Regresyon Ağırlığı	Karar
M14	Bu maddeyi daha net anlatan maddeler mevcut.	,330	Regresyon Yol Katsayısı Düşük Madde+ Uzman görüşü doğrultusunda kapsam ve yapı geçerliği bozulmuyor
M7	Maddenin yerini alabilecek benzer madde bulunmaktadır.	,300	Regresyon Yol Katsayısı Düşük Madde+ Uzman görüşü doğrultusunda kapsam ve yapı geçerliği bozulmuyor
M9	Bu madde kapsamı karşılamasına rağmen anlaşılır değil.	,350	Regresyon Yol Katsayısı Düşük Madde+ Uzman görüşü doğrultusunda kapsam ve yapı geçerliği bozulmuyor

Uzman görüşü doğrultusunda yapılan değişiklik sonrası model tekrar test edilmiş ve istenilen uyum indeks değerlerine ulaşılmıştır.



Şekil 1. YZDSYÖ'nün 1. düzey ve 2. düzey DFA analizine göre oluşturulmuş standardize yol diagramları

M7, M9, M14 numaralı maddelerin çıkartılmasıyla oluşturulan diyagrama göre (Bkz. Şekil 1) ölçek maddelerine ait standardize yol katsayıları ,51 - ,86 değişmektedir. Bir maddenin ilgili olduğu değişkeni temsil edebilmesi için sahip olduğu standardize yol katsayısının ,50'den büyük olması gerekmektedir

(Kline, 2016). Buna göre YZDSYÖ için yapılan DFA ile belirlenen standardize yol katsayısı değerleri bahsedilen faktörlerin ölçeğe ait maddeler tarafından temsil edilebildiğini göstermektedir.

Tablo 5. YZDSYÖ'nün 1. ve 2. Düzey Sonrası Belirlenen Uyum İndeks Değerleri

Uyum Ölçütü	Düzey DFA	Düzey DFA	Uyum Kriteri	Uyum Düzeyi
X ² /df	1,651	1,651	<5	Kabul Edilebilir Uyum
GFI	,903	,903	≥ .90	İyi Uyum
CFI	,919	,919	≥ .90	İyi Uyum
IFI	,920	,920	≥ .90	İyi Uyum
TLI	,909	,909	≥ .90	İyi Uyum
AGFI	,911	,911	≥ .90	İyi Uyum
RMSEA	,061	,061	0,05-0,08	Kabul Edilebilir Uyum

YZDSYÖ için gerçekleştirilen doğrulayıcı faktör analizi sonuçları değerlendirildiğinde modelin uyum istatistiklerinin veriyle tutarlılık gösterdiği görülmüştür. X²/df oranı 1,651 olarak hesaplanmış olup bu değer kabul edilebilir uyum sınırları içerisinde yer almakta ve modelin veri setine yeterli düzeyde uyum sağladığına işaret etmektedir (Kline, 2016). Mutlak ve karşılaştırmalı uyum indekslerinden GFI (.903), AGFI (.911), IFI (.920), TLI (.909) ve CFI (.919) değerleri kabul edilebilir eşiğin üzerindedir. Bu değerler dikkate alınarak ölçek modelinin veriyle iyi uyum gösterdiği ortaya konmaktadır (Hu ve Bentler, 1999). Hata yaklaşımını temsil eden RMSEA değeri 0,061 olarak bulunmuştur. RMSEA'nın 0.05'in altında olması mükemmel uyumu 0,05 ile 0,08 arasında olması ise kabul edilebilir uyumu ifade etmektedir (Browne & Cudeck, 1992). Elde edilen RMSEA değeri modelin kabul edilebilir düzeyde bir uyuma sahip olduğunu göstermektedir.

Birinci düzey DFA ile doğrulanan 3 faktörlü ve 22 maddelik yapı ikinci bir DFA ile üst düzey bir model olarak yeniden sınanmıştır. İkinci DFA sonucunda elde edilen uyum indeksleri (GFI (.903), AGFI (.911), IFI (.920), TLI (.909) ve CFI (.919)) kabul edilebilir düzeydedir. Elde edilen bu bulgulara göre 3 birinci düzey faktörün Yapay Zekâ Destekli Sınıf Ortamı isimli tek bir üst yapıyı oluşturan anlamlı bileşenler olduğunu ve ölçeğin hiyerarşik faktör yapısının geçerli olduğunu desteklemektedir.

3.1.3. Güvenirlilik Analizleri

Ölçeğin güvenilirliğini değerlendirmek amacıyla madde ayırt edicilik ve iç tutarlık analizleri gerçekleştirilmiştir. Ayırt edicilik analizi kapsamında üst (%27) ve alt (%27) gruplar arasındaki puan farklarını test etmek için bağımsız örneklemeler üzerinde t testi uygulanmıştır (Bkz. Tablo 6). Analiz sonuçları YZDSYÖ'nün 3 faktöründeki puanlar açısından iki grup arasında istatistiksel olarak anlamlı farklılıklar olduğunu göstermektedir ($p < .001$). Bu bulgu ölçeğin her bir alt boyutunun ölçülmek istenen özelliği yüksek ve düşük düzeyde gösteren bireyleri başarılı bir şekilde ayırt etme yeterliliğine sahip olduğuna işaret etmektedir.

Ölçeğin iç tutarlık düzeyini belirlemek amacıyla hem Cronbach's Alpha hem de McDonald's Omega katsayıları ve AVE hesaplanmıştır. Yapılan analizler sonucunda ölçeğin tüm alt boyutlarında ve ölçeğin genelinde her iki güvenilirlik katsayısının da ,70 eşiğinin üzerinde olduğu tespit edilmiştir. Ölçeğin yeterli bir iç tutarlığa sahip olduğunun söylenebilmesi için elde edilecek güvenilirlik katsayılarının ,70 ve üzeri olması gerekmektedir (Nunnally & Bernstein, 1994). Sonuç olarak hem ayırt edicilik hem de iç tutarlık analizlerinden elde edilen bulgular YZDSYÖ'nün genelinde ve alt boyutlarında güvenilir bir ölçüm aracı olduğunu ortaya koymaktadır.

Tablo 6. Yapay Zekâ Destekli Sınıf Yönetimi Ölçeği Güvenirlilik ve Yakınsak Geçerlilik Analizi Değerleri

Faktörler	Madde No	Üst ve alt grup farkı için t değeri	McDonald's Omega (ω)	Cronbach's Alpha (α)	AVE
Yapay Zekâ Entegrasyonu	Y1	12,332**	,88	,89	,58
	Y4	11,746**			
	Y7	11,529**			
	Y10	8,604**			
	Y13	9,413**			
	Y16	9,767**			
Dijital Etkileşim	Y2	6,726**	,83	,83	,51
	Y5	8,932**			
	Y8	6,696**			
	Y11	10,285**			
	Y14	10,701**			
	Y17	11,168**			
	Y19	7,754**			
Teknopeda gojik Altyapı	Y21	7,436**	,83	,82	,53
	Y3	8,291**			
	Y6	7,576**			
	Y9	6,408**			
	Y12	7,958**			
	Y15	6,035**			
	Y18	10,373**			
	Y20	6,740**			
Toplam ölçek	Y22	7,723**	,92	,91	,55

3.1.4. Ölçeğin Puanlanması

Yapay Zekâ Destekli Sınıf Yönetimi Ölçeği 5'li likert tipinde yanıt formatına sahip olarak geliştirilmiştir. Gerçekleştirilen tüm analiz sonuçları değerlendirildiğinde ölçeğin puanlanmasında dereceleme toplamaları (toplam puan) tekniğinin kullanılması uygun görülmüştür. Bu puanlama yöntemi ölçek geliştirme sürecinde homojen bir yapı oluşturma ve bireylerin hedeflenen kavrama yönelik genel eğilimlerini ortaya koyma açısından önemli avantajlar sağlamaktadır (Nunnally & Bernstein, 1994). Dereceleme toplamaları tekniğinin geçerli bir şekilde uygulanabilmesinin temel koşulu, ölçeğin bir bütün olarak yüksek iç tutarlığa sahip olması ve maddelerin birbiriyle anlamlı şekilde ilişkili olmasıdır (Kline, 2016). Yapılan güvenilirlik analizleri ölçeğin bu koşulları sağladığını göstermektedir. Ölçekten elde edilen toplam puan öğretmenlerin yapay zekâ destekli sınıf yönetimi becerilerini yansıtmaktadır. Ölçekten alınan yüksek puan öğretmenin yüksek düzeyde yapay zekâ destekli sınıf yönetimi becerisine sahip olduğunu; alınan düşük puan ise öğretmenin düşük düzeyde yapay zekâ destekli sınıf yönetimi becerisine sahip olduğunu göstermektedir.

Tablo 7. YZDSYÖ Puan Tablosu

YZDSYÖ Alt Boyutları	Maddeler	Alınabilecek En Düşük Puan	Alınabilecek En Yüksek Puan
Yapay Zekâ Entegrasyonu	Y1,Y4,Y7,Y10,Y13,Y16	6	30
Dijital Etkileşim	Y2,Y5,Y8,Y11,Y14,Y17,Y19,Y21	8	40
Teknopedagojik Altyapı	Y3,Y6,Y9,Y12,Y15,Y18,Y20,Y22	8	40
Toplam		22	110

Tablo 7 incelendiğinde öğretmenlerin yapay zekâ entegrasyonu alt boyutundan alabilecekleri en düşük puanın 6, en yüksek puanın ise 30 olduğu belirlenmiştir. Dijital etkileşim alt boyutunda ise öğretmenlerin en düşük alabileceği puan 8; en yüksek puan ise 40 olarak hesaplanmıştır. Son olarak teknopedagojik altyapı boyutu incelendiğinde ise yine öğretmenlerin en düşük alabileceği puan 8; en yüksek alabilecekleri puan ise 40 olarak belirlenmiştir. Öğretmenlerin aldığı puanlar yükseldikçe, öğretmenlerin yapay zekâ destekli sınıf yönetimi yeterlik düzeylerinin arttığını; öğretmenlerin aldığı puanlar düştükçe ise, öğretmenlerin yapay zekâ destekli sınıf yönetimi yeterlik düzeyinin yetersiz olduğunu göstermektedir. Ölçekten toplam puan alınabilmekte olup öğretmenler en az 22 puan, en fazla 110 puan alabilmektedirler.

4. TARTIŞMA ve SONUÇ

Dijitalleşme süreciyle birlikte eğitim alanında kullanım alanı giderek genişleyen yapay zekâ teknolojisi, dijital sınıf ortamlarının yapısını ve işleyişini temelden değiştirme potansiyeline sahip olarak görülebilir. Bu değişim, yalnızca geleneksel sınıf yönetimi anlayışını desteklemekle sınırlı olmayıp; öğretmenlerin idari ve ölçme-değerlendirme süreçlerindeki iş yüklerinin azaltılması, öğrenci davranışlarının öngörülebilmesi ve öğrenme süreçlerinin kişiselleştirilmesi gibi çok boyutlu yenilikleri de beraberinde getirmektedir. Yapay zekâ temelli sistemler, öğretim süreçlerini otomatikleştirme ve öğrenen özelliklerine göre uyarlama kapasitesi sayesinde, dijital sınıf ortamlarında etkili ve sürdürülebilir bir yönetim mekanizması sunmaktadır (Li, 2024).

Bu açıdan bakıldığında, dijital sınıflarda öğrenme analitiğine ait oluşturulan verilerinin anlamlı hâle getirilmesi, öğrencilerin akademik ve davranışsal gelişimlerinin izlenmesi, zamanında ve nitelikli geri bildirimlerin sağlanması ile içerik yönlendirmesinin optimize edilmesi, yapay zekâ entegrasyonu sayesinde daha sistematik ve etkili biçimde gerçekleştirilebilmektedir (Lin, 2023; MEB-Yeğitek, 2025; Rodriguez-Ortiz, 2025; Sajja vd., 2023; Wang vd., 2024). Bu yönüyle yapay zekâ, dijital sınıf yönetimini destekleyen yardımcı bir araç olmanın ötesine geçerek, öğrenme ortamlarının tasarımını ve işlevselliğini yeniden tanımlayan stratejik bir unsur olarak kabul görmektedir.

Bu dönüşüm süreci, dijital sınıf ortamlarında yapay zekâ destekli uygulamaların yalnızca teknik bir yenilik olarak değil, aynı zamanda pedagojik ve yönetsel bir yeterlik alanı olarak ele alınmasını zorunlu kılmaktadır. Ancak ilgili literatür incelendiğinde, yapay zekânın dijital sınıf yönetimine entegrasyonunun çoğunlukla sistemlerin teknik kapasitesi ya da öğrenci çıktıları üzerinden değerlendirildiği; öğretmenlerin bu süreçteki algıları, uygulama düzeyleri ve yönetsel yeterliklerinin sınırlı sayıda ölçme aracıyla ele alındığı görülmektedir (Ayanwale vd., 2023; Can & Ertuğ, 2021;). Oysa dijital sınıf ortamlarında yapay zekâ destekli yönetim süreçlerinin etkililiği, büyük ölçüde öğretmenlerin bu teknolojileri sınıf yönetimi bağlamında nasıl kullandıkları, hangi işlevleri önceliklendirdikleri ve bu uygulamaları pedagojik kararlarına nasıl yansıttıkları ile ilişkilidir. Bu gereksinimden hareketle, mevcut çalışmada geliştirilen ölçek, öğretmenlerin dijital sınıf ortamlarında yapay zekâ destekli yönetim uygulamalarına ilişkin algılarını ve yeterliklerini çok boyutlu bir yapı içinde değerlendirmeyi amaçlayarak yapay zekâ entegrasyonunun sınıf yönetimi bağlamında daha bütüncül ve ölçülebilir biçimde incelenmesine imkan oluşturmuştur.

Bu çalışmada geliştirilen ölçeğin psikometrik özellikleri; madde ayırt ediciliği, iç tutarlılık güvenirliği, yakınsak geçerlik, açıklanan varyans oranları ve doğrulayıcı faktör analizi sonuçları temelinde bütüncül

bir yaklaşımla değerlendirilmiştir. Elde edilen bulgular, ölçeğin kuramsal olarak öngörülen üç faktörlü yapısının ampirik verilerle büyük ölçüde örtüştüğünü ve ölçme açısından geçerli ve güvenilir bir araç sunduğunu göstermektedir.

Madde düzeyinde gerçekleştirilen analizler, ölçeğin tüm maddelerinin ölçülen yapıyı ayırt edici nitelikte olduğunu ortaya koymuştur. Üst ve alt grup karşılaştırmalarında elde edilen t değerlerinin tamamının istatistiksel olarak anlamlı olması, maddelerin düşük ve yüksek düzeydeki bireyleri ayırt etme gücüne sahip olduğunu göstermektedir. Bu bulgu, ölçeğin madde hassasiyetinin yüksek olduğunu ve ölçüm hatasının madde düzeyinde sınırlı kaldığını düşündürmektedir. Ölçeğin iç tutarlılık güvenilirliği, Cronbach's Alpha ve McDonald's Omega katsayıları birlikte ele alınarak değerlendirilmiştir. Faktör bazında Alpha değerlerinin ,82 ile ,89, Omega katsayılarının ise ,83 ile ,88 arasında değişmesi; toplam ölçek için $\alpha = ,91$ ve $\omega = ,92$ değerlerine ulaşılması, ölçeğin hem alt boyutlar hem de toplam puan düzeyinde yüksek güvenilirliğe sahip olduğunu ortaya koymaktadır. Özellikle Omega katsayısının raporlanması, faktör yüklerinin eşitliği varsayımına dayanmayan daha sağlam bir güvenilirlik değerlendirmesine olanak tanımakta ve çalışmanın metodolojik gücünü artırmaktadır.

Yakınsak geçerlik, Açıklanan Ortalama Varyans (AVE) değerleri üzerinden incelenmiştir. Her bir faktör için AVE değerlerinin ,51 ile ,58 arasında değişmesi ve toplam ölçek için AVE değerinin ,55 olarak hesaplanması, tüm faktörlerin önerilen ,50 eşik değerini karşıladığını göstermektedir. Bu bulgu, maddelerin ilişkili oldukları faktörleri yeterli düzeyde temsil ettiğini ve ölçeğin yakınsak geçerliğinin sağlandığını ortaya koymaktadır.

Açımlayıcı Faktör Analizi sonuçları, üç faktörlü yapının toplam varyansın %58,18'ini açıkladığını göstermektedir. Sosyal bilimler alanında %50'nin üzerindeki açıklanan varyans oranlarının yeterli kabul edildiği dikkate alındığında, bu oran ölçeğin faktör yapısının güçlü olduğunu ortaya koymaktadır. Faktörler bazında açıklanan varyans oranlarının dengeli bir dağılım göstermesi (Faktör 1: %22,24; Faktör 2: %20,24; Faktör 3: %15,69), her bir boyutun ölçülen yapıya anlamlı katkı sunduğunu göstermektedir. Gerçekleştirilen AFA sonucu elde edilen bu yapıya ait ilk faktör yapay zekâ entegrasyonu olarak isimlendirilmiştir ve Y1,Y4,Y7,Y10,Y13,Y16 numaralı maddelerden oluşmaktadır. Faktörün isimlendirilmesinde "Öğretmenimiz derslerdeki duygularımızı yapay zekâ destekli programlar aracılığıyla takip eder." (Y7), "Öğretmenimiz, derslerde yapay zekâ destekli programlar aracılığıyla derse olan katılımımızı takip eder. (Y16)" gibi ifadeler ve bu ifadelerin literatür ile uyumu dikkate alınmıştır. Yapay zekâ entegrasyonu; literatürde öğretmenlerin yapay zekâ okuryazarlığının eğitim süreçlerine entegre edilmesini (Ng vd., 2024), yapay zekânın öğretim süreçlerinde planlama rolünü (UNESCO, 2024), yapay zekânın eğitim-öğretimde öğrenim süreciyle bütünleştirilmesini kapsamaktadır (Luckin, 2018). Ölçeğin ikinci faktörüne dijital etkileşim ismi verilmiştir. Bu faktör Y2,Y5,Y8,Y11,Y14,Y17,Y19,Y21 numaralı maddelerden oluşmaktadır. Faktörde yer alan "Öğretmenimiz, dersten önce ders işleniş hakkında (dokümanlar, kurallar, ders süreci vb.) bilgi verir (Y5)" "Öğretmenimiz, ders sürecinde verdiğimiz tepkilere göre (sohbete yazdıklarımız, sözlü- yazılı cevaplarımız vb.) bize geri bildirimler verir. Y2" gibi maddeler kapsam açısından dijital etkileşimle ilişkilidir. Dijital etkileşim alt boyutu, literatürde öğretmen- öğrenci ilişkisinde dönütlerin nasıl verildiğini, öğrenci katılımını artıran ve teşvik eden stratejileri kapsamaktadır (Bond vd., 2021; Çelik, 2022; Hattie & Timperley, 2007; Martin & Bolliger, 2018; Sun vd., 2022). Ölçeğin üçüncü ve son faktörü Y3,Y6,Y9,Y12,Y15,Y18,Y20,Y22 numaralı maddeleri kapsamaktadır ve teknopedagojik altyapı olarak ifade edilmiştir. Faktörde yer alan "Öğretmenimiz ders içinde uymamız gereken temel kurallar ile ilgili (kamera açma, derse katılma, söz hakkı alma, mikrofon açma gibi) bilgiler verir. (Y15)" "Öğretim yönetimi ara sistemi ile ilgili teknik sorunların çözümü için öğretmenimizden yardım alırız. (Y12)" gibi maddeler kapsam açısından teknopedagojik altyapı ile ilişkili kavramlar barındırmaktadır. Teknopedagojik altyapı, literatürde teknolojinin pedagoji ile kesişimini açıklamakla (Mishra & Kohler, 2006) beraber sınıf ortamında kullanılan dijital ve teknolojik araçların pedagojik olarak nasıl uygun hâle getirildiğini kapsamaktadır (Tondeur vd., 2017).

Doğrulayıcı Faktör Analizi bulguları, ölçeğin üç faktörlü yapısının doğrulandığını ortaya koymaktadır. χ^2/df oranının 1,651 olması, modelin veriye oldukça iyi düzeyde uyum sağladığını göstermektedir. Yaklaşık uyum göstergelerinden RMSEA değerinin 0,061 olması, modelin kabul edilebilir hata düzeyine sahip olduğunu ve dengeli bir yapı sunduğunu ortaya koymaktadır. Karşılaştırmalı uyum indeksleri incelendiğinde, IFI (.920), TLI (.909) ve CFI (.919) değerlerinin tamamının ,90 eşik değerinin üzerinde olduğu görülmektedir. Bu bulgular, önerilen modelin bağımsız modele kıyasla anlamlı derecede daha iyi uyum sağladığını ve kuramsal yapının ampirik olarak desteklendiğini göstermektedir. Buna karşın GFI (.857) ve AGFI (.823) değerlerinin ideal eşiklerin altında kalması, modelin yapı geçerliğinin reddedilmesini gerektirmemektedir. Zira doğrulayıcı faktör analizinde model uyumunun değerlendirilmesi, tekil uyum indekslerine değil; χ^2/df , RMSEA ve CFI, TLI, IFI gibi karşılaştırmalı uyum göstergelerinin birlikte ele alındığı bütüncül bir yaklaşıma dayanmaktadır (Brown, 2015; Kline, 2016). Ayrıca GFI ve AGFI indekslerinin örneklem büyüklüğü, madde sayısı ve model karmaşıklığından yüksek düzeyde etkilendiği; bu nedenle modern DFA çalışmalarında ikincil uyum göstergeleri olarak değerlendirildiği belirtilmektedir (Hair vd., 2019). Bu bağlamda, modelin temel ve karşılaştırmalı uyum indekslerinin kabul edilebilir ya da iyi uyum düzeyinde olması, GFI ve AGFI değerlerindeki görece düşüklüğün modelin genel yapı geçerliğini zayıflatmadığını göstermektedir. Ölçeğin genelinde elde edilen uyum göstergeleri ve göreceli uyum ölçütleri birlikte değerlendirildiğinde, önerilen ölçüm modelinin yalnızca iyi uyum sağlamakla kalmadığı, aynı zamanda kuramsal açıklayıcılık ile yalın bir model yapısı arasında dengeli bir yapı sunduğu görülmektedir. Bu durum, ölçeğin ölçmek istediği yapıyı gereksiz parametreler eklemekten temsil edebildiğini ve metodolojik açıdan sağlam bir ölçme aracı olduğunu göstermektedir.

Sonuç olarak, madde ayırt ediciliği, yüksek iç tutarlılık katsayıları, yeterli AVE değerleri, güçlü açıklanan varyans oranları ve doğrulayıcı faktör analizi uyum indeksleri birlikte değerlendirildiğinde, bu çalışmada geliştirilen ölçeğin geçerli, güvenilir ve psikometrik açıdan güçlü bir ölçme aracı olduğu sonucuna ulaşılmaktadır. Bununla birlikte, ölçeğin farklı örneklemeler üzerinde yeniden test edilmesi ve ölçüm değişmezliği analizleri ile desteklenmesi, gelecekte yapılacak çalışmalar için önemli bir araştırma yönü olarak değerlendirilmektedir.

Kaynakça/Reference

- Ada, S. & Baysal, Z.N. (2020). *Sınıf yönetimi* (2. Baskı). Nobel.
- Ali, Q., Abbas, A., Raza, A., Khan, M. T. I., Zulfiqar, H., Iqbal, M. A., ... & Alotaibi, B. A. (2023). Exploring the students' perceived effectiveness of online education during the covid-19 pandemic: Empirical analysis using structural equation modeling (SEM). *Behavioral Sciences*, 13(7), 578. <https://doi.org/10.3390/bs13070578>
- Almuqhim, S. & Berri, J. (2025). AI-driven personalized microlearning framework for enhanced e-learning. *Computer Applications in Engineering Education*, 33(3). <https://doi.org/10.1002/cae.70040>
- Al-Sindi, T., Putra, H. D., & Ghazi, S. (2023). Integrating technology into classroom training. *Journal of Training, Education, Science and Technology*, 1-6. <https://doi.org/10.51629/jtest.v1i1.168>
- Ananda, K. R., Tjalla, M., Fakhruddin, Z., Mujahidah, M., & Sunubi, A. H. (2025). WEB 2.0 tools in English project based learning at elementary and high schools in Kabupaten Pinrang. *DEIKTIS: Jurnal Pendidikan Bahasa Dan Sastra*, 5(1), 81-88. <https://doi.org/10.53769/deiktis.v5i1.1295>
- Andhika, A., Aldila, A. S., Supriyono, L. A., Previana, C. N., & Habibie, D. R. (2024). The effectiveness of adaptive learning systems integrated with LMS in higher education. *Jurnal KomtekInfo*, 49-56. <https://doi.org/10.35134/komtekinfo.v11i2.505>
- Atun, H. & Usta, E. (2019). The effects of programming education planned with TPACK framework on learning outcomes. *Participatory Educational Research*, 6(2), 26-36. <https://doi.org/10.17275/per.19.10.6.2>
- Avedzi, J. E. (2025). Educational technology, teaching practices, and learning outcomes in Sub-Saharan Africa: Empirical insights from Ghana's basic education classrooms. <https://doi.org/10.21203/rs.3.rs-7330474/v1>
- Ayanwale, M. A., Adelana, O. P., & Odufuwa, T. T. (2024). Exploring STEAM teachers' trust in AI-based educational technologies: a structural equation modelling approach. *Discover Education*, 3(1). <https://doi.org/10.1007/s44217-024-00092-z>
- Badawy, W., Zinhom, H., & Shaban, M. (2024). Navigating ethical considerations in the use of artificial intelligence for patient care: A systematic review. *International Nursing Review*, 72(3). <https://doi.org/10.1111/inr.13059>
- Barocas, S., Hardt, M., & Narayanan, A. (2019). *Fairness and Machine Learning*. MIT Press. <https://fairmlbook.org>
- Begum, I. U. (2024). Role of artificial intelligence in higher education- An empirical investigation. *International Research Journal on Advanced Engineering and Management (IRJAEM)*, 2(03), 49-53. <https://doi.org/10.47392/irjaem.2024.0009>
- Bond, M., Bedenlier, S., Marín, V. I., & Händel, M. (2021). Emergency remote teaching in higher education: Mapping the first global online semester. *International Journal of Educational Technology in Higher Education*, 18(1), 1-24. <https://doi.org/10.1186/s41239-021-00282-x>
- Brown, T. A. (2015). *Confirmatory Factor Analysis for Applied Research* (2nd ed.). New York: The Guilford Press.
- Browne, M.W. and Cudeck, R. (1992) Alternative ways of assessing model fit. *Sociological Methods and Research*, 21, 230-258. <https://doi.org/10.1177/0049124192021002005>
- Büyüköztürk, Ş. (2024). *Sosyal Bilimler İçin Veri Analizi El Kitabı* (31. Baskı). Pegem Akademi.
- Byrne, B. M. (1998). *Structural equation modeling with LISREL, PRELIS, and SIMPLIS: Basic concepts, applications, and programming*. Lawrence Erlbaum Associates Publishers.
- Byrne, B. M. (2010). *Structural Equation Modeling with AMOS*. Routledge.
- Calvani, A., Fini, A., Ranieri, M., & Picci, P. (2012). Are young generations in secondary school digitally competent? A study on Italian teenagers. *Computers & Education*, 58(2), 797-807.

- Can, E. & Gündüz, Y. (2021). Öğretmenlerin sanal sınıf yönetimi yeterliği ölçeği: Geçerlik ve güvenirlik çalışması. *Bolu Abant İzzet Baysal Üniversitesi Eğitim Fakültesi Dergisi*, 21(2), 574-591. <https://dx.doi.org/10.17240/aibuefd.2021.21.62826-869543>
- Carolus, A., Augustin, Y., Markus, A., & Wienrich, C. (2023). Digital interaction literacy model—conceptualizing competencies for literate interactions with voice-based AI systems. *Computers and Education: Artificial Intelligence*, 4, 100114.
- Chatti, M. A., Muslim, A., Guliani, M., & Guesmi, M. (2020). *The LAVA model: Learning analytics meets visual analytics. In Adoption of data analytics in higher education learning and teaching (pp. 71-93)*. Cham: Springer International Publishing.
- Costello, A. B., & Osborne, J. (2005). Best practices in exploratory factor analysis: Four recommendations for getting the most from your analysis. *Practical Assessment Research & Evaluation*, 10, 1-9.
- Çelik, İ. (2022). Towards Intelligent-TPACK: An empirical study on teachers' professional knowledge to ethically integrate artificial intelligence (AI)-based tools into education. *Computers in Human Behaviour*, 138. <https://doi.org/10.1016/j.chb.2022.107468>
- Dampson, D. G. (2021). Determinants of learning management system adoption in an era of covid-19: Evidence from a Ghanaian University. *European Journal of Education and Pedagogy*, 2(3), 80-87. <https://doi.org/10.24018/ejedu.2021.2.3.94>
- Davids, A. I. R., Camarero-Figuerola, M., & Camacho, M. d. M. (2025). Navigating the challenges and opportunities of artificial intelligence in educational leadership: A scoping review. *Review of Education*, 13(2). <https://doi.org/10.1002/rev3.70101>
- DeVellis, R. F. (2017). *Scale Development: Theory and Applications (4th ed.)*. Thousand Oaks, CA: Sage.
- Dignum, V. (2019). *Responsible Artificial Intelligence: Developing and Using AI in a Responsible Way*. Springer. <https://doi.org/10.1007/978-3-030-30371-6>
- Dziuban, C. D., Graham, C. R., Moskal, P., Norberg, A., & Sicilia, N. (2018). Blended learning: the new normal and emerging technologies. *International Journal of Educational Technology in Higher Education*, 15(1). <https://doi.org/10.1186/s41239-017-0087-5>
- Echtenbruck, M. M., Fühles-Ubach, S., Naujoks, B., & Kaliva, E. (2025). A Data Literacy Competence Model for Higher Education and Research. *arXiv preprint arXiv:2504.15690*.
- Erdoğan, İ. (2019). *Sınıf yönetimi- Ders, konferans, panel ve seminer etkinliklerinde başarının yolları (21. Baskı)*. Alfa.
- Fabrigar, L. R., Wegener, D. T., MacCallum, R. C., & Strahan, E. J. (1999). Evaluating the use of exploratory factor analysis in psychological research. *Psychological Methods*, 4(3), 272-299.
- Field, A.P. (2018) *Discovering Statistics Using IBM SPSS Statistics. (5th Edt)*, Sage, Newbury Park.
- Floridi, L., & Cows, J. (2019). *A unified framework of five principles for AI in society*. Harvard Data Science Review. <https://doi.org/10.1162/99608f92.8cd550d1>
- Gharbaoui, H., Mansouri, K., & Poirier, F. (2023). Towards a social learning analysis using learning management system and learning experience to predict learners' success. *Lecture Notes in Computer Science*, 364-370. https://doi.org/10.1007/978-3-031-32883-1_33
- Gómez, M. J. M., Sánchez, Á. A., Albaladejo-González, M., Clemente, F. J. G., & Ruipérez-Valiente, J. A. (2025). Utilising explainable AI to enhance real-time student performance prediction in educational serious games. *Expert Systems*, 42(3). <https://doi.org/10.1111/exsy.70008>
- Grand View Research (2024). *Education technology market report*. <https://www.grandviewresearch.com/press-release/global-education-technology-market>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate data analysis (7th ed.)*. Pearson
- Hair, J.F., Hult, G.T.M., Ringle, C.M., Sarstedt, M., Danks, N.P., Ray, S. (2021). *An introduction to structural equation modeling. In: partial least squares structural equation modeling (pls-sem) using r. classroom companion: Business*. Springer, Cham. https://doi.org/10.1007/978-3-030-80519-7_1
- Hattie, J., & Timperley, H. (2007). The power of feedback. *Review of Educational Research*, 77(1), 81-112. <https://doi.org/10.3102/003465430298487>
- Henríquez, V. & Hilliger, I. (2024). Blended learning in rural K-12 education: Stakeholder dynamics and recommendations. *Journal of Computer Assisted Learning*, 40(4), 1463-1480. <https://doi.org/10.1111/jcal.12963>

- Holstein, K., McLaren, B., & Alevan, V. (2019). Designing for complementarity: Teacher and AI roles to support student learning. *International Journal of Artificial Intelligence in Education*, 29(3), 461–497. <https://doi.org/10.1007/s40593-019-00187-8>
- Horn, J. L. (1965). A rationale and test for the number of factors in factor analysis. *Psychometrika*, 30, 179-185. <https://doi.org/10.1007/BF02289447>
- Hu, L. T., & Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling*, 6, 1-55. <http://dx.doi.org/10.1080/10705519909540118>
- Ifenthaler, D., & Yau, J. Y. K. (2020). Utilising learning analytics to support study success in higher education: a systematic review. *Educational Technology Research and Development*, 68(4), 1961-1990. <https://link.springer.com/article/10.1007/s11423-020-09788-z>
- Ifenthaler, D., Mah, D. K., & Yau, J. Y. K. (2019). Utilising learning analytics for study success: Reflections on current empirical findings. In *Utilizing learning analytics to support study success* (pp. 27-36). Cham: Springer International Publishing. https://link.springer.com/chapter/10.1007/978-3-319-64792-0_2
- Jian, M. J. K. O. (2023). Personalized learning through AI. *Advances in Engineering Innovation*, 5(1), 16-19. <https://doi.org/10.54254/2977-3903/5/2023039>
- Jobin, A., Ienca, M., & Vayena, E. (2019). The global landscape of AI ethics guidelines. *Nature Machine Intelligence*, 1(9), 389-399. <https://doi.org/10.1038/s42256-019-0088-2>
- Kaiser, H.F. (1974) An index of factorial simplicity. *Psychometrika*, 39, 31-36. <http://dx.doi.org/10.1007/BF02291575>
- Keshavarz, M. & Yuan, L. Y. (2023). A narrative case history of distance education before, during, and after covid-19 in China and Iran. *Canadian Journal of Learning and Technology*, 49(1), 1-15. <https://doi.org/10.21432/cjlt28275>
- Kline, P. (2014). *An Easy Guide to Factor Analysis*. Routledge. <https://doi.org/10.4324/9781315788135>
- Krishnan, R., Nair, S., Saamuel, B. S., Justin, S., Iwendi, C., Biamba, C., ... & Ibeke, E. (2022). Smart analysis of learners performance using learning analytics for improving academic progression: A case study model. *Sustainability*, 14(6), 3378. <https://doi.org/10.3390/su14063378>
- Kuhfeld, M., Soland, J., Tarasawa, B., Johnson, A., Ruzek, E., & Liu, J. (2020). Projecting the potential impact of COVID-19 school closures on academic achievement. *Educational Researcher*, 49(8), 549-565.
- Kwangmuang, P., Jarutkamolpong, S., Sangboonraung, W., & Daungtod, S. (2021). The development of learning innovation to enhance higher order thinking skills for students in Thailand junior high schools. *Heliyon*, 7(6).
- Laupichler, M. C., Aster, A., Haverkamp, N., & Raupach, T. (2023). Development of the “Scale for the assessment of non-experts’ AI literacy”–An exploratory factor analysis. *Computers in Human Behavior Reports*, 12, 100338.
- Li, H. (2025). Research on student learning behavior analysis and precision teaching driven by big data. *Journal of Modern Educational Theory and Practice*, 1(3). <https://doi.org/10.70767/jmetp.v1i3.454>
- Li, W. (2024). The influence of artificial intelligence on the education system. *Lecture Notes in Education Psychology and Public Media*, 65(1), 137-142. <https://doi.org/10.54254/2753-7048/65/20240158>
- Lin, C. C., Huang, A. Y., & Lu, O. H. (2023). Artificial intelligence in intelligent tutoring systems toward sustainable education: a systematic review. *Smart learning environments*, 10(1), 41. <https://link.springer.com/article/10.1186/s40561-023-00260-y>
- Long, P., & Siemens, G. (2011). Penetrating the fog: Analytics in learning and education. *EDUCAUSE Review* (Online).
- López-Meneses, E., López-Catalán, L., Pelicano-Piris, N. & Mellado-Moreno, P. C. (2025). Artificial Intelligence in Educational Data Mining and Human-in-the-Loop Machine Learning and Machine Teaching. *Applied Sciences*, 15(2). <https://doi.org/10.3390/app15020772>

- Luckin, R. (2018). *Machine learning and human intelligence. The future of education for the 21st century*. UCL institute of education press.
- Mandinach, E. B., & Gummer, E. S. (2016). *Data literacy for educators: Making it count in teacher preparation and practice*. Teachers College Record, 118(11).
- Markets and Markets. (2024). *AI in education market by offering (software, services), technology (machine learning, natural language processing), application (learning platforms, virtual facilitators, intelligent tutoring), end user and region - Global forecast to 2030*. <https://www.marketsandmarkets.com/Market-Reports/ai-in-education-market-200371366.html>
- Martin, F., & Bolliger, D. U. (2018). Engagement matters: Student perceptions on the importance of engagement strategies in the online learning environment. *Online Learning Journal*, 22(1), 205–222. <https://doi.org/10.24059/olj.v22i1.1092>
- Meylani, R. (2024). Artificial intelligence in the education of teachers: A qualitative synthesis of the cutting-edge research literature. *Journal of Computer and Education Research*, 12(24), 600-637. <https://doi.org/10.18009/jcer.1477709>
- Millî Eğitim Bakanlığı (MEB) – YEGİTEK (2025). *Eğitimde Yapay Zekâ Politika Belgesi ve Eylem Planı (2025-2029)*. Belge, yapay zekâ sistemlerinin “bireyselleştirilmiş yönlendirme, anlık geri bildirim, öğrenme takibi” fonksiyonlarını desteklediğini resmi politika düzeyinde ifade ediyor. www.yegitek.meb.gov.tr
- Mozelius, P. & Hettiarachchi, E. (2017). Critical factors for implementing blended learning in higher education. *International Journal of Information and Communication Technologies in Education*, 6(2), 37-51. <https://doi.org/10.1515/ijicte-2017-0010>
- Mwalumbwe, I. & Mtebe, J. S. (2017). Using learning analytics to predict students' performance in moodle learning management system: A case of mbeya university of science and technology. *The Electronic Journal of Information Systems in Developing Countries*, 79(1), 1-13. <https://doi.org/10.1002/j.1681-4835.2017.tb00577.x>
- Nasir, M., Hasan, M., Adlim, A., & Syukri, M. (2024). *Utilizing artificial intelligence in education to enhance teaching effectiveness*. Proceedings of International Conference on Education, 2(1), 280-285. <https://doi.org/10.32672/pice.v2i1.1367>
- Ndalu, U. J. (2025). Educational Management and Artificial Intelligence for Sustainable Development in Nigeria. *International Journal of Educational Management*, Rivers State University, 1(2), 75-89. <https://ijedm.com/index.php/ijedm/article/view/46>
- Ng, D. T. K., Leung, J. K. L., Su, J., Ng, C. W., & Chu, S. K. W. (2023). Teachers' AI digital competencies and twenty-first century skills in the post-pandemic world. *Educational Technology Research and Development*, 71(1), 137-161. <https://doi.org/10.1007/s11423-023-10203-6>
- Ng, D. T. K., Wu, W., Leung, J. K. L., Chiu, T. K. F., & Chu, S. K. W. (2024). Design and validation of the AI literacy questionnaire: The affective, behavioural, cognitive and ethical approach. *British Journal of Educational Technology*, 55(3), 1082-1104.
- Nunnally, J.C. and Bernstein, I.H. (1994) The assessment of reliability. *Psychometric Theory*, 3, 248-292.
- OECD. (2021). *OECD Digital Education Outlook 2021: Pushing the frontiers with AI, blockchain and robots*. OECD Publishing. <https://doi.org/10.1787/589b283f-en>
- Papamitsiou, Z., & Economides, A. A. (2014). Learning analytics and educational data mining in practice: A systematic literature review of empirical evidence. *Journal of educational technology & society*, 17(4), 49-64.
- Polak, S., Schiavo, G., & Zancanaro, M. (2022). *Teachers' perspective on artificial intelligence education: an initial investigation*. CHI Conference on Human Factors in Computing Systems Extended Abstracts, 1-7. <https://doi.org/10.1145/3491101.3519866>
- Ragolane, M., Patel, S., & Salikram, P. (2024). AI versus human graders: Assessing the role of large language models in higher education. *Asian Journal of Education and Social Studies*, 50(10), 244-263. <https://doi.org/10.9734/ajess/2024/v50i101616>
- Rodríguez-Ortiz, M. Á., et al. (2025). Machine Learning and Generative AI in Learning Analytics. *Applied Sciences*, 15(15). <https://doi.org/10.3390/app15158679>

- 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.
- Sajja, R., Sermet, Y., Cwiertny, D., & Demir, I. (2023). Integrating AI and learning analytics for data-driven pedagogical decisions and personalized interventions in education. *ArXiv*. <https://arxiv.org/pdf/2312.09548>
- Savov, T., Terzieva, V., Todorova, K., & Kademova-Katzarova, P. (2017). *Contemporary technology support for education*. CBU International Conference Proceedings, 5, 802-806. <https://doi.org/10.12955/cbup.v5.1029>
- Schildkamp, K., & Poortman, C. L. (2015). *Factors influencing the functioning of data teams*. Teachers College Record, 117(4).
- Schreiber J. B. (2021). Issues and recommendations for exploratory factor analysis and principal component analysis. *Research In Social & Administrative Pharmacy: RSAP*, 17(5), 1004–1011. <https://doi.org/10.1016/j.sapharm.2020.07.027>
- Soto-Sanfiel, M. T., Angulo-Brunet, A., & Lutz, C. (2025). The scale of artificial intelligence literacy for all (SAIL4ALL): assessing knowledge of artificial intelligence in all adult populations. *Humanities and Social Sciences Communications*, 12(1), 1-14.
- Steiger, J. H. (2007). Understanding the Limitations of Global Fit Assessment in Structural Equation Modeling. *Personality and Individual Differences*, 42, 893-898. <https://doi.org/10.1016/j.paid.2006.09.017>
- Sun, J. C.-Y., Lin, C.-T., & Chou, C. (2022). Teacher–student interaction and its impact on students' engagement in online learning environments. *Frontiers in Psychology*, 13, 779217. <https://doi.org/10.3389/fpsyg.2022.779217>
- Szyska, M., Tomczyk, Ł., & Kochanowicz, A. M. (2022). Digitalisation of schools from the perspective of teachers' opinions and experiences: the frequency of ICT Use in education, attitudes towards new media, and support from management. *Sustainability*, 14(14), 8339. <https://doi.org/10.3390/su14148339>
- Tabachnick, B. G. & Fidell, L. S. (2013). *Using multivariate statistics (Sixth Edition)*. USA: Pearson Education Limited.
- Taşdan, M. & Yurttaş, A. (2022). *Sınıf yönetimi ve sanal eğitimle ilgili temel kavramlar*. M. Taşdan (Ed.), *Dijital çağda sınıf yönetimi içinde* (ss. 3- 28). Pegem Akademi.
- Tondeur, J., Forkosh-Baruch, A., Prestridge, S., Albion, P., & Edirisinghe, S. (2017). Responding to challenges in teacher professional development for ICT integration in education. *Educational Technology & Society*, 20(1), 110–120. <https://www.jstor.org/stable/90002177>
- Topali, P., Ortega-Arranz, A., Rodríguez-Triana, M. J., Er, E., Khalil, M. & Akçapınar, G. (2024). Designing human-centered learning analytics and artificial intelligence in education solutions: a systematic literature review. *Behaviour & Information Technology*. <https://doi.org/10.1080/0144929X.2024.2345295>
- Turan, S. (2020). *Sınıf yönetiminin temelleri*. M. Şişman & S. Turan (Ed.), *Sınıf yönetimi içinde* (ss. 2-17). Pegem Akademi.
- UNESCO. (2021). *Global education monitoring report 2021/2: Non-state actors in education: Who chooses? Who loses?*. United Nations Educational, Scientific and Cultural Organization. <https://doi.org/10.54676/XJFS2343>
- UNESCO. (2023). *Guidance for generative AI in education and research*. United Nations Educational, Scientific and Cultural Organization
- UNESCO. (2024). *AI competency framework for teachers*. United Nations Educational, Scientific and Cultural Organization. <https://doi.org/10.54675/ZJTE2084>
- Viberg, O., Cukurova, M., Feldman-Maggor, Y., Alexandron, G., Shirai, S., Kanemune, S., ... & Kizilcec, R. F. (2024). What explains teachers' trust in AI in education across six countries?. *International Journal of Artificial Intelligence in Education*, 35(3), 1288-1316. <https://doi.org/10.1007/s40593-024-00433-x>

- Wang, B., Rau, P. L. P., & Yuan, T. (2023). Measuring user competence in using artificial intelligence: validity and reliability of artificial intelligence literacy scale. *Behaviour & Information Technology*, 42(9), 1324-1337.
- Wang, S., Wang, F., Zhu, Z., Wang, J., Tran, T., & Du, Z. (2024). Artificial intelligence in education: A systematic literature review. *Expert systems with applications*, 252, 124167. <https://www.sciencedirect.com/science/article/pii/S0957417424010339#bi005>
- Wang, T., Manta, O., & Zhang, Y. (2023). The relationship between learning motivation and online learning performance: The mediating role of academic self-efficacy and flow experience. *International Journal of Emerging Technologies in Learning (ijET)*, 18(23), 27-38. <https://doi.org/10.3991/ijet.v18i23.43977>
- Wang, X., Li, L., Tan, S. C., Yang, L., & Lei, J. (2023). Preparing for AI-enhanced education: Conceptualizing and empirically examining teachers' AI readiness. *Computers In Human Behavior*, 146, 107798.
- Wang, Y., Wu, J., Chen, F., & Li, J. (2024). Analyzing teaching effects of blended learning with LMS: An empirical investigation. *IEEE Access*, 12, 42343-42356. <https://doi.org/10.1109/access.2024.3352169>
- Williamson, B., & Eynon, R. (2020). Algorithmic education governance: Regulating the digital datafication of education. *Learning, Media and Technology*, 45(1), 3-17. <https://doi.org/10.1080/17439884.2019.1623250>
- Woodruff, K., Hutson, J., & Arnone, K. (2023). Perceptions and barriers to adopting artificial intelligence in k-12 education: A survey of educators in fifty states. *Reimagining Education - The Role of E-Learning, Creativity, and Technology in the Post-Pandemic Era*. <https://doi.org/10.5772/intechopen.1002741>
- Worthington, R. L., & Whittaker, T. A. (2006). Scale development research: A content analysis and recommendations for best practices. *The Counseling Psychologist*, 34, 806-838. <https://doi.org/10.1177/0011000006288127>
- Yıldırım, A., & Şimşek, H. (2018). *Sosyal bilimlerde nitel araştırma yöntemleri* (11. Baskı). Seçkin.
- Zhan, C. and Cui, P. (2023). Predicament and strategy of campus football teaching under the background of artificial intelligence and deep learning. *Journal of Computational Methods in Sciences and Engineering*, 23(5), 2437-2449. <https://doi.org/10.3233/jcm-226840>
- Zhou, B. (2024). The comprehensive investigation of the role related to artificial intelligence in education. *Applied and Computational Engineering*, 36(1), 215-219. <https://doi.org/10.54254/2755-2721/36/20230449>

EXTENDED ABSTRACT

1. INTRODUCTION

Thanks to technological advancements from the past to the present, schools and classrooms—where teaching and learning take place and where teachers and pupils come together—have undergone significant changes. At the same time, as these changes have also emerged in response to individuals' needs, major transformations have begun to be observed among both pupils and teachers. Consequently, the concept of classroom management has begun to be reshaped today to facilitate the adaptation of individuals whose needs and expectations are evolving. The integration of artificial intelligence, which has emerged with digitalisation, into digital classroom environments has paved the way for major changes, such as reducing teachers' administrative burdens, predicting student behaviour, and delivering personalised education, alongside traditional classroom management. In an AI-supported digital classroom environment, by analysing students' behavioural patterns, it enables teachers to act proactively and adapt their support measures to meet students' needs at an appropriate level. Research conducted at the K-12 level indicates that the adoption of AI-supported educational technologies is increasing, with approximately 20–30 per cent of institutions using some form of AI application in their educational processes. This expectation of rapid transformation is creating a significant gap in terms of teacher competencies. Research indicates that over 50% of teachers do not feel confident in effectively using AI-supported tools in their lessons. Furthermore, AI and digital literacy scales in the international literature assess teachers' competencies in this field across dimensions such as technical knowledge, application and ethics. In addition, the most comprehensive AI literacy scales in this field—such as MAILS, AILS/AILQ, SNAIL, MAIL-CS and SAIL4ALL—which are considered the most comprehensive AI literacy scales in this field—generally assess teachers' competencies at the level of individual knowledge and awareness; however, they do not directly measure the effects of AI-supported or digital classroom management on pedagogical decision-making, classroom interaction and the learning experience. Consequently, although current assessment tools appear sufficient for measuring specific competencies in the digital and artificial intelligence domains, there is no assessment tool that directly addresses the competencies teachers possess in AI-supported digital classroom environments within the context of classroom management and enables the evaluation of these competencies in relation to students. Therefore, there is a clear need for new and original assessment tools in this emerging field. Consequently, there is a need for this scale development study.

2. METHOD

The study group for the Artificial Intelligence-Supported Classroom Management Scale consisted of students attending state and private schools during the 2024–2025 academic year who had participated in various courses on online platforms during the current academic year. A criterion sampling method was used to conduct validity and reliability analyses of the developed AI-SCMS. Taking into account that the developed AI-Supported Classroom Management Scale (YZDSY) comprises 35 items, 486 students were included in the study group. For the AFA and DFA conducted as part of the validity and reliability analyses, separate study groups of the same nature were formed. The AFA process of the study was carried out with study groups comprising 239 students, whilst the DFA process was conducted with groups comprising 247 students. During the development process of the Artificial Intelligence-Supported Classroom Management Scale (YZDSYÖ), the theoretical framework of the structure to be measured was examined in detail whilst creating the item pool for the scale. In this context, systematic reviews of the relevant literature were conducted, and the theoretical approach underpinning the scale, scales measuring similar constructs, and findings from various studies on the subject were taken into account. The draft item pool was submitted for evaluation by academic experts in the field to ensure the content and face validity of the measurement tool. In line with feedback from the experts, the wording of some items was simplified, concepts were clarified, and various adjustments were made to ensure suitability for the target audience. At the end of this process, the draft form comprising 30 items sent for expert review was reduced to 28

items. Following this, the YZDSY Scale proceeded to the pilot application phase. The 28-item pilot form, obtained following expert feedback and necessary adjustments, was administered to a pilot study group of 39 participants to test the clarity, feasibility, and answerability of the items, as well as the scale's preliminary reliability, prior to the main application. In addition, a separate study group comprising 21 students was established to determine the extent to which the items in the draft scale form were understood. Furthermore, the average response time for the scale was determined using a different study group comprising 18 students. The scale was completed by participants in an average of 10 minutes. Prior to conducting validity and reliability analyses of the scale, the data obtained were examined for missing data, outliers and the assumption of normality. In calculating outliers, the Z-score was taken into account, and data falling outside the range of -3 to +3 were classified as outliers. To determine the factor structure of the YZDSY Scale, exploratory factor analysis (EFA) was first applied. The Kaiser-Meyer-Olkin (KMO) coefficient and Bartlett's Sphericity Test were applied to determine whether the research data were suitable for factor analysis. Principal Components Analysis (PCA) was used in the factor analysis. The Varimax orthogonal rotation technique was preferred to enhance the interpretability of the factors. Confirmatory factor analysis (CFA) was applied to validate the factor structure obtained from the PCA. The goodness of fit of the model obtained from the CFA was assessed using the χ^2/df , RMSEA, CFI, GFI, NFI and IFI indices. The internal consistency of the structure obtained from AFA and DFA was calculated using Cronbach's Alpha, McDonald's Omega and AVE coefficients. For internal consistency, Cronbach's Alpha and McDonald's Omega were considered sufficient if they were above ,70, and the AVE coefficient was considered sufficient if it was above ,50.

3. RESULTS

The suitability of the data collected within the scope of the study for factor analysis was tested using the Kaiser-Meyer-Olkin (KMO) sample adequacy test and Bartlett's sphericity test. According to the results obtained, the KMO value was determined to be ,907. The chi-square value obtained from the Bartlett's Sphericity Test was found to be statistically significant ($\chi^2 = 1792,974$; $p < 0.001$). The AFA results for the YZDSYÖ were examined using the Slope-Loading Plot (Figure 1). Based on this result, the optimal number of factors for the YZDSYÖ was accepted as three. Following the AFA, items with factor loadings below ,30 and items loading on more than one factor (M1, M8, M24) were removed after consulting experts, and the analyses were repeated. Three of the 28 items of the YZDSYÖ were removed in line with the analyses and expert opinion, resulting in a 25-item structure. The AFA process was repeated from the beginning after each item was removed. According to the findings, the 25-item structure was found to explain 58,186% of the total variance. In naming the components of the three-factor structure of the YZDSYÖ, the literature on AI-supported classroom management and digital classroom management was taken into account. The first factor of the YZDSYÖ consists of items M16, M4, M7, M12, M3, M15 and M21. Taking the item wording into account, this factor was named 'Artificial Intelligence Integration'. The scale's second factor comprises items M5, M2, M20, M11, M14, M17, M22, M8 and M24. This factor has been named 'Digital Interaction'. The third factor of the YZDSYÖ comprises items M10, M9, M19, M18, M23, M1, M25, M6 and M13, and has been termed 'Technopedagogical Infrastructure'. It was found that the correlations between the three factors derived from the YZDSYÖ were positive and statistically significant. The 25-item structure identified at the conclusion of the exploratory factor analysis conducted for the YZDSYÖ was retested using DFA. During the analysis process, it was found that items M7, M9 and M14 had high error variances and low regression weights. Consequently, these items were removed to improve the model, and the analyses were repeated. According to the diagram created following the removal of items M7, M9 and M14 (see Figure 2), the standardised path coefficients for the scale items range from ,51 to ,86. Upon evaluating the results of the confirmatory factor analysis conducted for the YZDSYÖ, it was observed that the model's fit statistics were consistent with the data. The Chi-square/degrees of freedom (χ^2/df) ratio was calculated as 1,651; this value falls within acceptable fit limits and indicates that the model provides an adequate fit to the data set. The values of the absolute and comparative fit indices—GFI (0,903), AGFI (0,911), IFI (0,920), TLI (0,909) and CFI (0,919)—are above the acceptable threshold. Taking these values into account, it is demonstrated that the scale model fits the data well. The RMSEA value, representing the error term, was found to be 0,061. The three-factor, 22-item structure validated by the first-order DFA was retested as a

higher-order model using a second DFA. The fit indices obtained from the second DFA (GFI (0,903), AGFI (0,911), IFI (0,920), TLI (0,909) and CFI (0,919)) are at an acceptable level. Item discrimination and internal consistency analyses were conducted to assess the reliability of the scale. As part of the discriminant analysis, an independent samples t-test was applied to test the score differences between the upper (27%) and lower (27%) groups (see Table 6). The analysis results indicate that there are statistically significant differences between the two groups in terms of scores on the three factors of the AI-Supported Classroom Management Skills Scale ($p<.001$). The Artificial Intelligence-Supported Classroom Management Scale was developed using a 5-point Likert-type response format. Upon evaluating all the analysis results, it was deemed appropriate to use the sum of ratings (total score) technique for scoring the scale. A total score can be obtained from the scale, with teachers able to achieve a minimum of 22 points and a maximum of 110 points.

ARAŞTIRMANIN ETİK İZNİ

Bu çalışmada “Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi” kapsamında uyulması gerektiği belirtilen tüm kurallara uyulmuştur. Yönergenin ikinci bölümü olan “Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler” başlığı altında belirtilen eylemlerden hiçbiri gerçekleştirilmemiştir.

Etik kurul izin bilgileri

Etik değerlendirmeyi yapan kurul adı: Necmettin Erbakan Üniversitesi Etik Kurulu

Etik değerlendirme kararının tarihi: 10.01.2025

Etik değerlendirme belgesi sayı numarası: 2025/02

ARAŞTIRMACILARIN KATKI ORANI

Araştırmacıların her birinin mevcut araştırmaya katkısı; 1. yazarın araştırmaya katkı oranı %50, 2. yazarın araştırmaya katkı oranı %50’dir.

Yazar 1: Danışmanlık, veri analizi, raporlaştırma.

Yazar 2: Yöntemin belirlenmesi, alan yazın taraması, geçerlik ve güvenirlik çalışmaları.