

## Yapay Zekâ Destekli Karar Destek Sistemleri ve Yönetim Bilişim Sistemlerine Entegrasyonu

Vahid Sinap<sup>1</sup>

### Özet

Bu çalışma, yapay zekâ (YZ) destekli karar destek sistemlerinin (KDS) yönetim bilişim sistemleri (YBS) ile entegrasyonunu inceleyerek, işletmelerin karar alma süreçlerindeki dönüşümünü ele almaktadır. Günümüz iş dünyasında artan veri hacmi ve karmaşıklığı, geleneksel karar alma yöntemlerini yetersiz kılmakta; bu nedenle veri odaklı, dinamik ve otomatik çözümler sunan YZ destekli KDS'ler (YZ-KDS) önem kazanmaktadır. Makine öğrenmesi ve derin öğrenme gibi teknolojiler, büyük veri analitiği, tahminleme ve optimizasyon gibi alanlarda KDS'leri güçlendirerek, işletmelerin operasyonel verimliliğini artırmakta ve stratejik rekabet avantajı sağlamaktadır. YZ-KDS'ler, yapılandırılmış ve yapılandırılmamış verileri analiz ederek, geçmiş verilerden öğrenip geleceğe yönelik senaryolar sunabilmektedir. Ancak, bu sistemlerin başarısı veri kalitesi, model şeffaflığı, ölçeklenebilirlik ve güvenlik gibi faktörlere bağlıdır. Derin öğrenme modellerinin “kara kutu (black box)” niteliği, şeffaflık ve yorumlanabilirlik zorlukları yaratırken, açıklanabilir yapay zekâ (Explainable Artificial Intelligence - XAI) yaklaşımları bu sorunlara çözüm sunmaktadır. Ayrıca, veri güvenliği ve etik konular, sistemlerin uygulanabilirliğini etkileyen kritik unsurlardır; anonimleştirme, şifreleme ve erişim kontrolü gibi yöntemler bu alanda öne çıkmaktadır. YZ-KDS'nin YBS ile entegrasyonu, finans, tedarik zinciri ve insan kaynakları gibi alanlarda stratejik planlamayı desteklemekte; ancak teknik, yönetsel ve etik boyutların dengelenmesi gerekmektedir. Gelecekte kuantum hesaplama ve sürekli öğrenme gibi yenilikler, bu sistemlerin potansiyelini artıracaktır. İşletmeler, veri odaklı karar alma kapasitelerini güçlendirmek için bu teknolojilere yatırım yapmalı ve etik ile güvenlik standartlarını gözetmelidir.

1 Dr. Öğretim Üyesi, Ufuk Üniversitesi, vahidsinap@gmail.com,  
<https://orcid.org/0000-0002-8734-9509>

## 1. Giriş

Günümüz iş dünyasında karar verme süreçleri giderek daha karmaşık hale gelmekte ve küresel rekabet koşulları, teknolojik gelişmeler ile artan veri hacmi nedeniyle yöneticilerin hızlı ve doğru kararlar almasını zorunlu kılmaktadır. Geleneksel karar alma süreçleri, deneyim, sezgi ve geçmiş verilere dayalı analizlerden oluşurken (Okoli ve Watt, 2018), günümüzde veri odaklı karar verme yaklaşımı giderek yaygınlaşmaktadır. Yöneticilerin ve karar vericilerin daha bilinçli, sistematik ve veriye dayalı kararlar almasına yardımcı olmak amacıyla geliştirilmiş bilişim sistemlerine ise KDS denilmektedir (Mumali, 2022). KDS'ler, işletmelerin operasyonel verimliliğini artırmak, riskleri minimize etmek ve stratejik planlamalarını optimize etmek için büyük ölçekli veri analizi, modelleme ve simülasyon tekniklerinden yararlanmaktadır. Geleneksel KDS'ler kural tabanlı sistemler ve analitik modelleme yöntemleri üzerine kuruludur (Soufi vd., 2018). Bu sistemler, geçmiş verilere dayalı analizler yaparak belirli senaryolar için karar önerileri sunmaktadır. Ancak, bu tür sistemlerin büyük ölçekli ve dinamik verileri işleme kapasitesi sınırlı olduğundan, günümüzün hızla değişen iş ortamına tam anlamıyla uyum sağlamak yetersiz kalabilmektedir (Selvarajan, 2022). YZ-KDS'ler, bu eksiklikleri gidermek üzere geliştirilmiş, makine öğrenmesi (Machine Learning - ML) ve derin öğrenme (Deep Learning - DL) gibi yapay zekâ tekniklerinden faydalanarak daha özerk, dinamik ve hassas karar destek mekanizmaları sunan sistemlerdir.

YZ-KDS'ler, büyük veri analitiği, tahminleme, optimizasyon, otomatik karar verme ve örüntü tanıma gibi alanlarda önemli gelişmeler sağlamaktadır. ML ve DL tabanlı algoritmalar, kural tabanlı sistemlerin aksine, yalnızca geçmiş verilere dayalı tahminleme yapmakla kalmayıp, aynı zamanda sürekli olarak yeni verilerden öğrenerek karar verme süreçlerini iyileştirmektedir (Janiesch vd., 2021). Bu sistemler, veri madenciliği, doğal dil işleme (Natural Language Processing - NLP), bulanık mantık ve sinir ağları gibi teknikleri kullanarak yapılandırılmış ve yapılandırılmamış verileri analiz edebilmekte, öngörülerde bulunabilmekte ve yöneticilere en uygun karar senaryolarını sunabilmektedir.

Büyük veri çağında işletmeler, müşteri davranışlarını anlamak, operasyonel süreçleri optimize etmek ve rekabet avantajı elde etmek için YZ-KDS'leri benimsemektedir (Rasul vd., 2025). Perakende sektöründen finans hizmetlerine, sağlık sektöründen üretim sektörüne kadar geniş bir yelpazede kullanılan bu sistemler, karar destek süreçlerini otomatikleştirerek ve daha akıllı hale getirerek işletmelerin daha esnek ve proaktif kararlar almasını sağlamaktadır. Ancak, bu dönüşüm süreci sadece teknik bir evrim değil, aynı

zamanda yönetsel, organizasyonel ve etik boyutları da içeren kapsamlı bir değişimi gerektirmektedir. Bu noktada, YZ-KDS'nin sunduğu fırsatlar kadar karşılaşılan zorluklar da dikkate alınmalıdır. Büyük veri ile entegrasyon, algoritmaların doğruluğu, şeffaflık, güvenilirlik, veri güvenliği ve etik karar verme gibi faktörler, bu sistemlerin etkin kullanımı açısından kritik öneme sahiptir (Gupta vd., 2022). Yöneticilerin ve işletmelerin, bu teknolojilere uyum sağlayabilmesi için YZ-KDS'lerin avantajlarının, sınırlılıklarının ve gelecekteki gelişim alanlarının iyi anlaşılması gerekmektedir. Bu kapsamda, bu araştırma, YZ-KDS'nin temel bileşenlerini, işletmelerdeki uygulamalarını, büyük veri ve iş zekâsı ile entegrasyonunu kapsamlı bir şekilde ele almaktadır. Ayrıca, bu sistemlerin avantajları, karşılaşılan zorluklar ve gelecekteki yönelimleri tartışılarak, YZ-KDS'lerin YBS ile nasıl bütünleşebileceği değerlendirilecektir. Bu bağlamda, araştırma hem teorik hem de uygulamalı bir çerçeve sunarak, YZ-KDS'lerin evrimini anlamaya, karşılaşılan zorlukları belirlemeye ve gelecekteki potansiyel etkilerini değerlendirmeye yönelik kapsamlı bir bakış açısı sağlamayı amaçlamaktadır.

## 2. ML ve DL'nin Karar Destek Süreçlerine Etkisi

ML ve DL, günümüzde karar destek süreçlerinde köklü bir dönüşüm yaratmaktadır. KDS, büyük ölçüde kurallara dayalı ve statik modelleme teknikleri üzerine inşa edilirken, makine öğrenmesi ve DL, veriye dayalı dinamik modelleme yaklaşımını benimseyerek daha esnek ve etkili çözümler sunmaktadır. Bu teknolojiler, geniş ve karmaşık veri kümelerinden anlamlı bilgileri otomatik olarak çıkararak karar alma süreçlerini desteklemekte, hatta belirli durumlarda otonom karar mekanizmaları oluşturmaktadır (Taherdoost, 2023).

Makine öğrenmesi, istatistiksel yöntemler ve algoritmalar kullanarak veriler arasındaki örüntüleri keşfetmeyi ve bu örüntülerden öğrenerek tahminler yapmayı amaçlayan bir yapay zekâ alt alanıdır (Sarker, 2021). Denetimli, denetimsiz ve pekiştirmeli öğrenme gibi farklı öğrenme yöntemleri, çeşitli karar destek süreçlerine entegre edilerek işletmelerin ve kamu kurumlarının daha bilinçli kararlar almasını sağlamaktadır. Denetimli öğrenme algoritmaları, geçmiş verilere dayanarak belirli bir olayın gerçekleşme olasılığını tahmin ederken (Wang ve Reddy, 2019), denetimsiz öğrenme yöntemleri büyük ve yapılandırılmamış veri setlerinde gizli örüntüleri ortaya çıkararak bilinmeyen bilgileri gün yüzüne çıkarabilmektedir (Usama vd., 2019). Pekiştirmeli öğrenme ise özellikle dinamik ve değişken ortamlarda optimal karar stratejileri geliştirmek için yaygın olarak kullanılmaktadır (Nguyen vd., 2020). Bunların yanı sıra, makine öğrenmesinin bir alt dalı olan DL, özellikle büyük veri analizi ve karmaşık problem çözme süreçlerinde

önemli avantajlar sunmaktadır. Çok katmanlı yapay sinir ağları sayesinde yüksek boyutlu verileri işleyebilme yeteneğine sahip olan DL modelleri, görüntü tanıma, NLP, öneri sistemleri ve anomali tespiti gibi birçok alanda etkin bir şekilde kullanılmaktadır (Najafabadi vd., 2015). KDS'de DL uygulamaları, yüksek hacimli verilerin daha doğru ve hızlı analiz edilmesini sağlarken, insan müdahalesine duyulan ihtiyacı azaltarak otomatik karar alma mekanizmalarının gelişmesine katkıda bulunmaktadır.

ML ve DL, KDS'nin temel yapısını değiştirerek daha veri odaklı, adaptif ve öngörülebilir hale getirmektedir. ML ve DL tabanlı yaklaşımlar, sistemleri veri güdümlü hale getirerek, karar alma süreçlerinde dinamik ve öğrenen mekanizmaların kullanılmasını sağlamaktadır (Heidari vd., 2022). Bu dönüşüm, yalnızca mevcut bilginin işlenmesini değil, aynı zamanda yeni verilerle kendini güncelleyebilen, karmaşık ilişkileri keşfedebilen ve çok boyutlu değişkenler arasında anlamlı örüntüler oluşturabilen sistemlerin geliştirilmesine olanak tanımaktadır. ML, karar destek süreçlerine adaptasyon ve tahmin gücü olmak üzere iki temel avantaj sağlamaktadır. Adaptasyon yeteneği sayesinde, ML algoritmaları çevresel değişimlere hızlı bir şekilde uyum sağlayarak karar süreçlerini güncelleyebilmektedir. Bu, özellikle dinamik ve öngörülemeyen koşullar altında karar alma mekanizmalarının etkinliğini artırmaktadır (Bagheri vd., 2024). Tahmin gücü ise büyük ve karmaşık veri setleri üzerinden istatistiksel ve matematiksel modeller kurarak gelecekteki olası senaryoları belirleme kapasitesi sunmaktadır (Ekundayo, 2024). Böylece, karar alıcılar yalnızca geçmiş verilere dayalı çıkarımlar yapmak zorunda kalmamakta, aynı zamanda olası riskleri ve fırsatları önceden analiz ederek stratejik kararlarını şekillendirebilmektedir.

ML, adaptasyon ve tahmin gücü sağlayarak KDS'yi daha esnek ve öngörülebilir hale getirirken, DL ise bu dönüşümü bir adım öteye taşıyarak çok katmanlı yapay sinir ağlarıyla daha karmaşık veri yapılarını modelleyebilmektedir. ML yöntemleri belirli özelliklerin (features) manuel olarak belirlenmesini gerektirirken, DL bu süreci otomatik hale getirerek yüksek boyutlu ve yapılandırılmamış verilerden anlam çıkarma kapasitesine sahiptir (Najafabadi vd., 2015). Bu durum, çeşitli kaynaklardan gelen verilerin işlenmesi ve analiz edilmesi açısından kritik bir avantaj sunmaktadır. DL modelleri, veriler arasındaki doğrusal olmayan ilişkileri keşfetme, gizli örüntüleri ortaya çıkarma ve veri içindeki enformasyonu yüksek doğrulukla çıkarma yeteneği sayesinde KDS'nin daha esnek ve güçlü hale gelmesine katkıda bulunmaktadır (Malak vd., 2019). Tablo 1'de, geleneksel KDS ile YZ-KDS arasındaki temel farklar karşılaştırmalı olarak verilmiştir.

Tablo 1. Geleneksel KDS ve YZ-KDS Karşılaştırması

Özellik	Geleneksel KDS	YZ-KDS
Veri Türü	Yapılandırılmış verilerle çalışır	Yapılandırılmış ve yapılandırılmamış verileri işler
Analiz Yöntemi	Kurallara dayalı analiz ve istatistiksel yöntemler kullanır	ML, DL ve veri madenciliği tekniklerini kullanır
Uyarlanabilirlik	Önceden tanımlı kurallar çerçevesinde çalışır, değişen verilere karşı esneklik sınırlıdır	Sürekli öğrenme mekanizmalarına sahiptir, değişen verilere uyum sağlayabilir
Karar Verme Süreci	Karar alma süreci genellikle insan müdahalesine dayanır	Otomatik karar önerileri sunar, bazı durumlarda özerk kararlar alabilir
Hız ve Verimlilik	Büyük veri setlerini işlemek için optimize edilmemiştir	Gerçek zamanlı veri işleme ve öngörücü analitik özelliklerine sahiptir
Şeffaflık ve Açıklanabilirlik	Karar mantığı açık ve yorumlanabilir	Bazı modeller “kara kutu” niteliğinde olup açıklanabilirliği düşük olabilir
Öngörü Yeteneği	Geçmiş verilere dayalı analiz sunar, geleceğe yönelik tahmin yeteneği sınırlıdır	Öngörücü analitik kullanarak geleceğe yönelik tahminlerde bulunabilir
Kullanım Alanları	Geleneksel iş zekası uygulamaları, raporlama ve veri analitiği	Özerk sistemler, büyük veri analitiği, tahmine dayalı modelleme

KDS’de ML ve DL’nin etkin bir şekilde uygulanabilmesi için, verilerin güvenilirliği, algoritmaların yorumlanabilirliği ve sistemlerin hesaplama maliyetleri gibi temel unsurların dikkatlice ele alınması gerekmektedir. Veri güvenilirliği, modellerin sağlıklı bir şekilde çalışması için kritik bir faktördür; hatalı, eksik veya yanlı (biased) verilerle eğitilen sistemler, yanlış yönlendirilmiş kararlar alınmasına yol açabilmektedir (Munappy vd., 2022). Bu nedenle, veri işleme süreçlerinin doğruluğunu ve bütünlüğünü sağlamak, KDS’nin güvenilirliğini artırmada önemli bir adımdır. Bunun yanı sıra, ML ve DL tabanlı sistemlerin yorumlanabilirliği, karar vericilerin modelleri anlamasını ve güvenilir bir şekilde kullanmasını sağlayan temel bir gerekliliktir. DL algoritmalarının genellikle “kara kutu” olarak nitelendirilmesi, bu sistemlerin içsel mekanizmalarının ve karar süreçlerinin açıklanmasını zorlaştırmaktadır (Guidotti vd., 2018). Bu nedenle, XAI yaklaşımları, KDS’de şeffaflık sağlamak ve model çıktılarının doğrulanabilirliğini artırmak amacıyla geliştirilmektedir. Yorumlanabilirlik, yalnızca güvenilir karar alma süreçlerini desteklemekle kalmaz, aynı zamanda etik ve regülasyon gerekliliklerine

uyum açısından da kritik bir rol oynamaktadır (Lisboa vd., 2023). Bir diğer önemli faktör, ML ve DL algoritmalarının hesaplama maliyetleridir. Gelişmiş algoritmalar, büyük veri kümelerini işlerken yüksek hesaplama gücü ve enerji tüketimi gerektirebilir (Adadi, 2021). Bu durum, KDS'nin verimliliğini etkileyebileceği gibi, operasyonel maliyetleri de artırabilir. Bu nedenle, kaynakların etkin bir şekilde kullanılması ve optimize edilmiş algoritmaların geliştirilmesi, KDS'nin sürdürülebilirliğini sağlamak açısından önemli bir strateji olarak öne çıkmaktadır.

ML ve DL, KDS'de önemli bir paradigma değişimi yaratmakta ve veri odaklı, öngörücü ve dinamik karar süreçlerinin oluşmasını sağlamaktadır. Ancak, bu teknolojilerin başarılı bir şekilde entegrasyonu, veri kalitesi, model yorumlanabilirliği ve hesaplama maliyetleri gibi kritik faktörlerin dikkatle yönetilmesini gerektirmektedir. Gelecekte, daha gelişmiş ve şeffaf yapay zekâ modellerinin geliştirilmesiyle birlikte, ML ve DL'nin karar destek süreçlerindeki rolünün daha da güçlenmesi ve organizasyonların karar alma süreçlerini daha bilinçli ve etkili bir şekilde yönlendirmelerine olanak tanınması beklenmektedir.

### **3. KDS'nin YBS'deki Stratejik Rolü**

YBS, organizasyonların veri toplama, işleme, analiz etme ve stratejik karar alma süreçlerini destekleyen bilişim teknolojileri bütünüdür (Berisha-Shaqiri, 2014). YBS, işletmelerin operasyonel ve yönetsel faaliyetlerini daha verimli hale getirmek için bilgi teknolojilerini kullanarak veri yönetimi, iş zekâsı ve karar verme süreçlerini optimize etmeyi amaçlamaktadır. Bu sistemler, organizasyonların iç ve dış çevrelerinden gelen verileri entegre ederek anlamlı bilgilere dönüştürmesine, kurumsal kaynakları daha etkin yönetmesine ve rekabet avantajı elde etmesine yardımcı olmaktadır (Alawamleh vd., 2021). Günümüz dijital ekonomisinde YBS, müşteri ilişkileri yönetiminden tedarik zinciri yönetimine, finansal analizlerden insan kaynakları yönetimine kadar geniş bir yelpazede kritik roller üstlenmektedir. YBS kapsamında KDS'ler, işletmelerin operasyonel ve stratejik karar alma süreçlerini daha verimli hale getiren temel bileşenlerden biridir (Biswas vd., 2024). YBS ile bütünleşen modern KDS'ler, işletmelerin geleceğe yönelik stratejik planlar geliştirmesine ve olası riskleri önceden belirlemesine olanak tanımaktadır.

KDS'nin YBS içindeki rolü, bilgi yönetimi süreçlerinin etkinleştirilmesi ve analitik yetkinliklerin artırılmasıyla doğrudan ilişkilidir. Finansal yönetim, operasyonel planlama, risk değerlendirme ve kaynak tahsisi gibi kritik karar süreçlerinde KDS'nin sağladığı destek, işletmelerin stratejik hedeflerine ulaşmasını kolaylaştırmaktadır. Finansal analiz süreçlerinde KDS, farklı piyasa

koşullarına dayalı senaryo modellemeleri oluşturarak yöneticilere optimal yatırım stratejileri ve bütçeleme kararları konusunda rehberlik etmektedir (Jia vd., 2022). Bu bağlamda, ML ve istatistiksel analiz yöntemleri kullanılarak yapılan tahminleme modelleri, piyasa dalgalanmalarını öngörmek ve potansiyel riskleri minimize etmek için güçlü bir karar destek mekanizması sunmaktadır. Benzer şekilde, insan kaynakları yönetimi bağlamında KDS, çalışan performans analizleri, yetenek yönetimi ve iş gücü optimizasyonu gibi süreçlerde veri analitiği desteği sağlayarak, işletmelerin daha nesnel ve veriye dayalı kararlar almasını mümkün kılmaktadır (Tuli vd., 2018). Çalışan bağlılığı, işe alım süreçleri ve eğitim gereksinimleri gibi konularda büyük veri analizinin kullanılması, insan kaynakları yöneticilerine daha stratejik bir bakış açısı kazandırmakta ve organizasyonların uzun vadeli yetenek yönetimi politikalarını şekillendirmelerine yardımcı olmaktadır (Dahlbom vd., 2020). Tedarik zinciri yönetimi ve operasyonel süreçler açısından değerlendirildiğinde ise KDS'nin sağladığı tahminleme ve optimizasyon teknikleri, işletmelerin stok yönetimi, lojistik planlama ve talep tahmin süreçlerini daha verimli hale getirmesine olanak tanımaktadır. Gerçek zamanlı veri analitiği ve simülasyon yöntemlerinin entegrasyonu sayesinde, işletmeler küresel tedarik zinciri ağlarını daha etkin bir şekilde yönetebilmekte ve operasyonel maliyetlerini düşürerek rekabet avantajı elde edebilmektedir (Ivano ve Dolgui, 2021).

Stratejik planlama ve risk yönetimi, KDS'nin YBS ile bütünleştiği bir diğer kritik alandır. İşletmeler, uzun vadeli hedeflerini belirlerken ve belirsizlikleri minimize etmeye yönelik stratejiler geliştirirken, büyük veri analitiği ve yapay zekâ tabanlı modelleme teknikleriyle desteklenen KDS'den önemli ölçüde faydalanmaktadır (Rane vd., 2024). Bu sistemler hem öngörüselleşen hem de normatif analitik yöntemleri kullanarak yöneticilere veri odaklı içgörüler sunmakta ve karar alma süreçlerinin rasyonelleştirilmesine katkıda bulunmaktadır. Tedarik zinciri yönetiminde KDS, talep tahminleme, stok optimizasyonu ve lojistik süreçlerin koordinasyonu gibi temel işlevleri yerine getirmektedir. ML ve istatistiksel modelleme teknikleri, geçmiş satış verileri, pazar eğilimleri ve mevsimsel değişkenler gibi faktörleri değerlendirerek gelecekteki talep düzeylerini öngörmekte ve işletmelere envanter yönetiminde daha etkin stratejiler geliştirme fırsatı sunmaktadır (Kharfan vd., 2021). Gerçek zamanlı veri akışlarının kullanılmasıyla, tedarik zinciri boyunca oluşabilecek aksaklıklar önceden tespit edilerek alternatif senaryolar oluşturulmakta ve operasyonel verimlilik artırılmaktadır (Ivanov ve Dolgui, 2021). Benzer şekilde, bankacılık ve finans sektöründe KDS, risk yönetimi ve kredi değerlendirme süreçlerinde kritik bir rol oynamaktadır. Klasik risk analiz yöntemlerinin ötesine geçerek, ML algoritmaları ve ileri düzey istatistiksel modelleme teknikleri ile kredi riskini daha hassas bir

şekilde ölçmekte ve yatırım kararlarının daha güvenilir verilere dayanmasını sağlamaktadır (Bello, 2023). Örneğin, bireysel kredi başvurularında KDS, başvuru sahibinin finansal geçmişini, gelir düzeyini, ödeme alışkanlıklarını ve ekonomik göstergeleri analiz ederek kredi skorlarını belirlemekte ve bankaların daha düşük riskle kredi tahsisi yapmasına imkân tanımaktadır (Sinap, 2024a). Ayrıca, finansal piyasalardaki dalgalanmaların modellenmesi ve simülasyon teknikleri aracılığıyla portföy yönetimi kararlarının optimize edilmesi, KDS'nin sağladığı en önemli katkılardan biridir. Stratejik planlama süreçlerinde KDS'nin sunduğu senaryo analizi ve çok kriterli karar verme teknikleri, işletmelerin uzun vadeli büyüme ve sürdürülebilirlik hedeflerini daha sağlam temellere dayandırmasına olanak tanımaktadır (Razmak ve Aouni, 2015). Bir işletme yeni bir pazara girmeyi planladığında, KDS'nin sağladığı pazar analizi, rakip değerlendirmesi ve müşteri davranış tahminleri gibi faktörler, stratejik kararların daha bilinçli bir şekilde alınmasını desteklemektedir. Ayrıca, küresel ekonomik dalgalanmalar, jeopolitik riskler ve düzenleyici değişiklikler gibi dış faktörlerin modellenmesiyle, işletmeler proaktif risk yönetimi yaklaşımlarını benimseyerek kriz senaryolarına karşı daha hazırlıklı hale gelmektedir (Rimon, 2024).

KDS, yalnızca stratejik planlama ve risk yönetimi süreçlerinde değil, aynı zamanda operasyonel verimliliğin artırılması ve karar alma süreçlerinin otomasyonu açısından da önemli bir rol oynamaktadır. Günümüzün dinamik ve rekabetçi iş ortamında, doğru ve zamanında alınan kararlar, işletmelerin sürdürülebilir rekabet avantajı elde etmeleri açısından büyük bir öneme sahiptir. Önceden tanımlı kurallar ile yürütülen karar alma süreçleri, yoğun insan müdahalesine ve manuel analizlere dayandığından hem zaman alıcı hem de hata payı yüksek olmaktadır. YZ-KDS çözümleri, veri odaklı karar alma süreçlerini geliştirerek işletmelerin değişken koşullara hızla uyum sağlamasını mümkün kılmaktadır.

Bu sistemlerin en önemli avantajlarından biri, sürekli öğrenme kapasitesine sahip olmalarıdır. ML algoritmaları, geçmiş kararlar ve sonuçları analiz ederek model doğruluğunu sürekli iyileştirmekte ve zaman içinde daha isabetli tahminler yapabilmektedir. Böylece, işletmelerin karar süreçleri daha esnek ve uyarlanabilir hale gelmekte, operasyonel verimlilik en üst düzeye çıkarılmaktadır. E-ticaret sektöründe, YZ-KDS çözümleri, müşteri davranışlarını analiz ederek kişiselleştirilmiş öneriler sunmakta ve işletmelerin gelir artışına doğrudan katkıda bulunmaktadır (Erdoğan, 2023). Öneri sistemleri, tüketicilerin geçmiş satın alma alışkanlıklarını, gezinme geçmişlerini ve demografik bilgilerini analiz ederek bireysel tercihlere uygun ürün ve hizmet önerileri oluşturabilmektedir. Benzer şekilde, perakende sektöründe dinamik fiyatlandırma algoritmaları, piyasa talebini,



stok seviyelerini ve rekabetçi fiyatlandırma stratejilerini değerlendirerek optimal fiyat seviyelerini belirlemekte ve kârlılığı artırmaktadır (Das vd., 2024). Bunun yanı sıra, üretim ve lojistik sektörlerinde KDS, tedarik zinciri yönetiminde envanter optimizasyonu, üretim planlaması ve lojistik rota belirleme gibi kritik işlevleri yerine getirmektedir (Hrabec vd., 2022). Gerçek zamanlı veri entegrasyonu sayesinde, tedarik süreçlerindeki aksamalar önceden tespit edilerek gerekli önlemler alınabilmekte, böylece operasyonel verimlilik artırılmaktadır. Örneğin, otomotiv sektöründe üretim hatlarında kullanılan KDS, tedarik zincirindeki gecikmeleri tahmin ederek üretim süreçlerini optimize etmekte, böylece kaynak kullanımı ve maliyetler açısından önemli tasarruflar sağlanmaktadır.

#### 4. Büyük Veri ve İş Zekâsı ile Entegrasyonu

Büyük veri ve iş zekâsı, KDS'nin temel bileşenleri olarak modern organizasyonların veri odaklı yaklaşımlar geliştirmesine olanak tanımaktadır. Büyük veri, yüksek hacimli, yüksek hızlı ve çeşitli kaynaklardan gelen yapılandırılmış ve yapılandırılmamış verileri ifade ederken (Chunarkar-Patil ve Bhosale, 2018), iş zekâsı bu verileri anlamlandırarak stratejik ve operasyonel karar süreçlerine entegre eden sistematik bir yapı sunmaktadır (Shollo ve Galliers, 2016). Büyük veri ortamlarında veri akışı dinamik olup, geleneksel yöntemlerle işlenmesi güç olan heterojen ve hızlı değişen veri kaynaklarını içerebilmektedir. Bu nedenle, büyük veri analitiği için gelişmiş ML algoritmaları, dağıtık işlem sistemleri ve gerçek zamanlı veri işleme teknikleri kullanılmaktadır. İş zekâsı sistemleri ise büyük veri platformlarıyla uyumlu çalışarak, veri madenciliği, tahmine dayalı analitik ve görselleştirme teknikleri aracılığıyla karar vericilere hızlı ve anlamlı içgörüler sunmakta, geçmiş eğilimleri analiz ederek geleceğe yönelik senaryolar oluşturmaktadır. Böylece, organizasyonlar daha bilinçli, kanıta dayalı ve öngörülebilir karar alma süreçleri sürdürebilmektedir. Bu entegrasyon, KDS'nin etkinliğini artırarak büyük ve karmaşık veri kümelerinin iş zekâsı süreçleriyle bütünleşik bir şekilde analiz edilmesini sağlamaktadır.

Büyük veri ile iş zekâsı entegrasyonunda kritik unsurlardan biri olan veri kalitesi, KDS'nin doğruluğunu ve güvenilirliğini doğrudan etkilemektedir. Yüksek hacimli veri kullanımı, sistemlerin yalnızca büyük miktarda veri toplamasını değil, aynı zamanda bu verilerin doğruluğunu, tutarlılığını ve anlamlılığını sağlamasını gerektirmektedir. Veri kalitesinin düşük olması, yanlış analiz sonuçlarına ve hatalı karar mekanizmalarına yol açarak organizasyonların stratejik hedeflerini riske atabilmektedir (Karkouch vd., 2016). Bu nedenle, veri temizleme (data cleansing), veri doğrulama (data

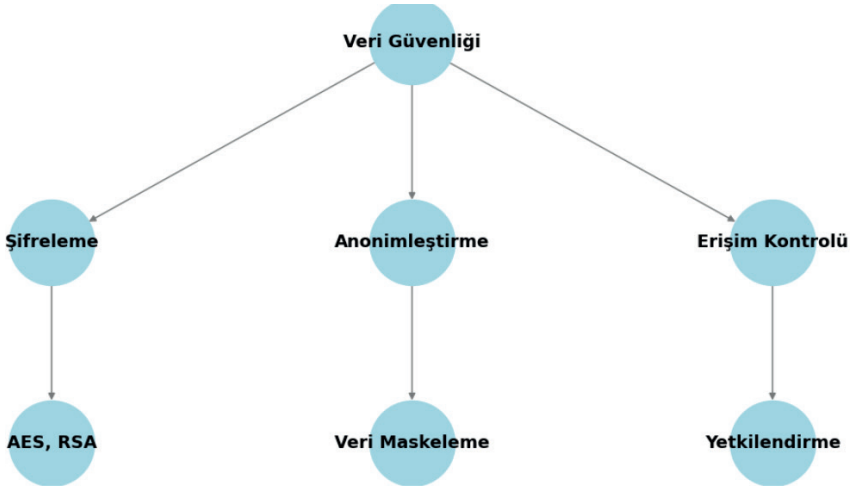
validation) ve anlamsal bütünlük (semantic consistency) süreçleri büyük veri ekosisteminin sağlıklı işlenmesi açısından büyük öneme sahiptir.

Veri temizleme süreci, hatalı, eksik veya çelişkili verileri belirleyerek bunları düzeltme veya sistemden çıkarma işlemlerini kapsamaktadır. Eksik verilerin tamamlanması, yinelenen verilerin elimine edilmesi ve anomalilerin tespit edilerek düzeltilmesi, büyük veri analizinin güvenilir sonuçlar üretmesi için gereklidir (Gudivada vd., 2017). Veri doğrulama ise verilerin güvenilir kaynaklardan gelip gelmediğini, içeriğinin mantıksal olarak tutarlı olup olmadığını ve iş süreçleriyle uyumlu çalışıp çalışmadığını denetleyen mekanizmaları içermektedir (Brinch, 2018). Diğer yandan, anlamsal bütünlük süreci farklı kaynaklardan gelen veri setlerinin tutarlı ve bağlamsal olarak anlamlı bir şekilde birleşmesini sağlamaya yönelik teknikler geliştirilmesini kapsamaktadır. Bu süreçler, büyük veri ve iş zekâsı sistemlerinin karar destek mekanizmalarına sağladığı faydayı en üst düzeye çıkarmaktadır.

Büyük veri ekosisteminde bir diğer önemli unsur, ölçeklenebilirlik ve hesaplama maliyetleridir. Büyük veri sistemleri, sürekli büyüyen ve hızla değişen veri akışlarını işleyebilme kapasitesine sahip olmalıdır. Veri işleme sistemleri, artan veri hacmi ve iş yükü karşısında yetersiz kalabilmektedir. Bu bağlamda, paralel işlem teknikleri, bulut bilişim ve dağıtık hesaplama sistemleri gibi teknolojiler büyük veri analitiğinin ölçeklenebilirliğini artırmaktadır (Yang vd., 2017). Paralel işlem teknikleri, büyük veri kümelerini eşzamanlı olarak analiz edebilmek için veriyi alt parçalara bölerek farklı işlem birimlerine yönlendirmektedir. Bu sayede, analiz süreçleri daha hızlı ve verimli hale getirilmektedir. Bulut bilişim altyapıları, yüksek işlem gücü gerektiren büyük veri analizlerini, ölçeklenebilir ve esnek bir yapıya sahip platformlarda gerçekleştirme imkânı sunmaktadır. Organizasyonlar, bulut tabanlı büyük veri çözümleri sayesinde hem operasyonel maliyetlerini optimize edebilmekte hem de artan veri yüklerine anında yanıt verebilecek dinamik sistemler oluşturabilmektedir (Elhoseny vd., 2018). Dağıtık hesaplama sistemleri, büyük veri işleme süreçlerini farklı sunuculara bölerek yük dengelemesi yapmakta ve veri işleme süreçlerinin kesintisiz devam etmesini sağlamaktadır (Al-Jumaili vd., 2023). Ancak, bu tür sistemlerin etkin kullanımı için altyapısal yatırımların dikkatle yönetilmesi ve optimizasyon süreçlerinin sağlıklı bir şekilde yürütülmesi gerekmektedir.

Büyük veri ve iş zekâsı entegrasyonunda bir diğer kritik konu, veri güvenliği ve gizliliğidir. Veri yönetim süreçlerinde, hassas bilgilerin korunması, yetkisiz erişimlerin önlenmesi ve veri bütünlüğünün sağlanması büyük önem taşımaktadır. Finans, sağlık ve kamu yönetimi gibi sektörlerde büyük veri analitiği kullanımı arttıkça, veri güvenliğine ilişkin

riskler de giderek artmaktadır (Vassakis vd., 2018). Bunun yanı sıra, veri güvenliği konusunda dikkate alınması gereken en önemli unsurlardan biri erişim kontrol mekanizmalarıdır. Organizasyonlar, veri setlerine erişimi yalnızca yetkilendirilmiş kullanıcılarla sınırlandırarak veri sızıntısı ve yetkisiz manipülasyon risklerini minimize edebilmektedir. Bu bağlamda, anonimleştirme teknikleri, güvenli veri paylaşım protokolleri, çok faktörlü kimlik doğrulama (Multi Factor Authentication - MFA), veri şifreleme yöntemleri ve erişim izleme sistemleri gibi güvenlik önlemleri, büyük veri ekosistemlerinin korunmasına yönelik önemli bileşenlerdir (Omotunde ve Ahmed, 2023). Şekil 1'de, veri güvenliği mekanizmalarının temel bileşenleri ve aralarındaki ilişkileri gösteren bir blok diyagramı verilmiştir.



Şekil 1. Veri Güvenliği Mekanizmaları Blok Diyagramı

Anonimleştirme teknikleri, büyük veri sistemlerinde kişisel veya hassas bilgilerin korunmasına yönelik temel stratejilerden biridir. Bu teknikler, veri setlerindeki kimlik belirleyici unsurların kaldırılması veya değiştirilmesi yoluyla, bireylerin veya kuruluşların doğrudan tanımlanmasını engellemek için geliştirilmiştir. Özellikle Avrupa Birliği Genel Veri Koruma Yönetmeliği (General Data Protection Regulation - GDPR) ve Kişisel Verileri Koruma Kanunu (KVKK) gibi yasal düzenlemeler çerçevesinde anonimleştirme, veri güvenliği ve gizliliğin sağlanması açısından kritik bir gereklilik haline gelmiştir. Bu bağlamda, anonimleştirme yöntemleri farklı teknikler kullanarak veri gizliliğini sağlamayı amaçlamaktadır. Bu tekniklerden biri olan k-anonimlik, verilerin belirli bir k sayıda kişi için aynı olacak şekilde gruplandırılmasını sağlayarak bireysel kimliklerin belirlenmesini zorlaştırırken (Mahanan vd.,

2020), l-çeşitlilik yöntemi, yalnızca kimlik belirleyici unsurların değil, aynı zamanda hassas verilerin de çeşitlendirilerek korunmasını hedeflemektedir (Sei vd., 2017). Anonimleştirme sürecinde, bireylerin kimliklerinin korunmasını sağlamanın bir diğer yöntemi de diferansiyel gizlilik yaklaşımıdır. Bu teknik, veri setlerine belirli miktarda rastgele gürültü ekleyerek, bireylerin doğrudan tanımlanmasını imkânsız hale getiren bir yapı sunmaktadır (Hassan vd., 2019).

Bununla birlikte, veri güvenliğini sağlamada anonimleştirme teknikleri tek başına yeterli olmayabilmektedir. Hassas verilerin korunması için ek güvenlik önlemlerine de ihtiyaç duyulmaktadır. Bu noktada, güvenli veri paylaşım protokolleri devreye girerek, organizasyonlar arası veri transferinin güvenli hale getirilmesini ve siber tehditlere karşı korunmasını sağlamaktadır. Büyük veri analiz süreçlerinde farklı kaynaklardan gelen verilerin işlenmesi ve paylaşılması gerekliliği, veri paylaşım güvenliğinin önemini artırmaktadır. Bu doğrultuda, veri şifreleme protokolleri, blokzincir (blockchain) teknolojisi ve güvenilir çalıştırma ortamları (Trusted Execution Environments - TEE) gibi mekanizmalar yaygın olarak kullanılmaktadır. Veri şifreleme protokolleri, verinin aktarım öncesinde ve sırasında şifrenmesini sağlayarak yetkisiz erişimlerin önüne geçmektedir. Gelişmiş Şifreleme Standardı (Advanced Encryption Standard - AES) ve RSA şifreleme algoritmaları, büyük veri güvenliği açısından en yaygın kullanılan yöntemler arasında yer almaktadır (Matta vd., 2021). Blokzincir tabanlı sistemler, verinin merkezi olmayan bir defterde kayıt altına alınmasını sağlayarak, güvenilirlik ve bütünlük açısından önemli avantajlar sunmaktadır (Zhang vd., 2020). Tedarik zinciri yönetimi, sağlık hizmetleri ve finans sektörlerinde güvenli veri paylaşım süreçlerini destekleyen blokzincir teknolojisi, yetkisiz veri manipülasyonlarını önleyerek güvenliği artırmaktadır.

Büyük veri ekosistemlerinde veri güvenliği, yalnızca verilerin korunmasıyla sınırlı değildir; aynı zamanda bu verilere erişimin kimler tarafından ve nasıl sağlandığının da titizlikle yönetilmesini gerektirir. Bu noktada, erişim kontrol mekanizmaları devreye girerek, yetkisiz erişimlerin önlenmesi ve veri bütünlüğünün korunması açısından kritik bir rol oynamaktadır. MFA, büyük veri ekosistemlerinde erişim güvenliğini artıran en önemli yöntemlerden biridir. Geleneksel kullanıcı adı ve şifre kombinasyonlarının güvenlik açıklarını gidermek amacıyla geliştirilen bu yöntem, kullanıcıların sisteme erişmeden önce birden fazla kimlik doğrulama katmanını aşmasını zorunlu kılmaktadır. En yaygın MFA teknikleri arasında şifre ile tek kullanımlık doğrulama kodu (One Time Password - OTP), biyometrik kimlik doğrulama sistemleri ve fiziksel güvenlik anahtarları bulunmaktadır (Mohammed vd., 2023). Biyometrik kimlik doğrulama yöntemleri, parmak izi, yüz tanıma ve retina

tarama gibi biyolojik özellikleri temel alarak, kullanıcıların kimliklerinin daha güvenilir bir şekilde doğrulanmasını sağlamaktadır (Kodituwakku, 2015). Fiziksel güvenlik anahtarları ise USB veya NFC tabanlı cihazlar aracılığıyla erişim güvenliğini artırarak, yalnızca yetkilendirilmiş cihazlar üzerinden büyük veri sistemlerine erişim imkânı tanımaktadır.

Erişim güvenliği aynı zamanda veri şifreleme yöntemleriyle de desteklenmelidir. Veri şifreleme yöntemleri, büyük veri sistemlerinde veri bütünlüğünü sağlamak ve yetkisiz erişimlerin önüne geçmek amacıyla kullanılan en önemli güvenlik mekanizmalarından biridir. Veri şifreleme, bilgilerin yalnızca yetkili kişiler veya sistemler tarafından okunabilir hale getirilmesini sağlayarak, büyük veri ekosistemlerinde veri sızıntılarını önleyen bir katman oluşturmaktadır. Simetrik ve asimetrik şifreleme yöntemleri, büyük veri güvenliğinde yaygın olarak kullanılan tekniklerdir. Simetrik şifreleme sistemlerinde, şifreleme ve şifre çözme işlemleri için aynı anahtar kullanılırken, asimetrik şifreleme yöntemlerinde iki farklı anahtar (genel anahtar ve özel anahtar) kullanılarak, daha güvenli bir veri şifreleme süreci oluşturulmaktadır (Suguna vd., 2016). AES gibi simetrik şifreleme algoritmaları, yüksek performanslı veri işleme süreçlerinde etkin bir şekilde kullanılabilirken, RSA gibi asimetrik şifreleme algoritmaları, özellikle veri paylaşımı ve kullanıcı doğrulama süreçlerinde güvenliği artırmaktadır (Mohamad vd., 2021). Büyük veri şifreleme süreçlerinin etkin bir şekilde yönetilmesi, sistem performansını olumsuz etkilemeden veri güvenliğini sağlamak açısından önem taşımaktadır.

Büyük veri ekosistemlerinde güvenliği sağlamak sadece erişimi kontrol altına almakla bitmemekte, yetkili kullanıcıların eylemlerini izleyerek anormal davranışları tespit edebilmek diğer bir zorluk olarak ortaya çıkmaktadır. Erişim izleme sistemleri, büyük veri ekosistemlerinde güvenlik ihlallerini tespit etmek, yetkisiz erişimleri önlemek ve veri güvenliği politikalarının uygulanabilirliğini artırmak amacıyla kullanılan kritik enstrümanlardır (Bertino ve Ferrari, 2017). Bu sistemler, kullanıcıların veri erişim hareketlerini sürekli olarak izleyerek, anormal veya şüpheli davranışları tespit etmek için geliştirilmiştir. Büyük veri tabanlarında erişim kayıtlarının analiz edilmesi, veri manipülasyon girişimlerinin tespit edilmesine olanak tanımakta ve veri güvenliğini tehdit eden unsurların önceden belirlenmesini sağlamaktadır (Zuech vd., 2015). Bu sistemler, güvenlik politikalarının uygulanmasını destekleyerek, organizasyonların büyük veri altyapılarında risk yönetimi süreçlerini daha etkin bir şekilde yürütmesine katkı sağlamaktadır.

Büyük veri ve iş zekâsı entegrasyonunda veri güvenliği ve gizliliğin sağlanması, anonimleştirme teknikleri, güvenli veri paylaşım protokolleri,

çok faktörlü kimlik doğrulama, veri şifreleme yöntemleri ve erişim izleme sistemleri gibi çok boyutlu güvenlik stratejilerinin uygulanmasını gerektirmektedir. Gelişen siber tehditlere karşı büyük veri sistemlerinin korunması, organizasyonların güvenlik altyapılarını sürekli olarak güncellemelerini ve yeni nesil güvenlik çözümlerini etkin bir şekilde kullanmalarını zorunlu kılmaktadır. Gelecekte kuantum kriptografi, sıfır güven mimarisi (Zero Trust Architecture - ZTA) ve yapay zekâ destekli güvenlik sistemleri gibi yenilikçi çözümlerin, büyük veri güvenliğini daha da güçlendirmesi ve organizasyonların veri odaklı karar alma süreçlerinde daha güvenli bir ortam yaratmalarına olanak tanınması beklenmektedir.

### 5. YZ-KDS'de Veri Yönetimi ve Teknik Zorluklar

YZ-KDS'nin en büyük avantajlarından biri, yüksek hacimli veriyi işleyebilme kapasitesidir. Araştırmanın daha önceki bölümlerinde de bahsedildiği üzere günümüzde organizasyonlar sürekli artan miktarda veriye maruz kalmakta ve bu verilerin anlamlı bilgilere dönüştürülmesi bir gereklilik haline gelmektedir. NLP ve görüntü işleme gibi YZ'nin alt disiplinleri sayesinde, metin, ses ve görseller gibi veri türlerinden içgörüler elde edilebilmekte ve karar destek mekanizmaları güçlendirilmektedir. Tablo 2, yapılandırılmış ve yapılandırılmamış veri türlerinin temel özelliklerini karşılaştırarak, veri yönetimi ve analitiği açısından farklılıklarını ortaya koymaktadır.

*Tablo 2. Yapılandırılmış ve Yapılandırılmamış Verinin Karşılaştırılması*

Özellik	Yapılandırılmış Veri	Yapılandırılmamış Veri
Tanım	Belirli bir formatta düzenlenmiş, satır ve sütunlardan oluşan veri türü.	Belirli bir formatı olmayan, düzensiz ve serbest biçimli veri.
Depolama	İlişkisel veri tabanlarında (SQL, MySQL, PostgreSQL) saklanır.	NoSQL veri tabanları, büyük veri platformları ve dosya sistemlerinde saklanır.
Veri Formatı	Tablo, matris, veri çerçevesi gibi yapılandırılmış formatlar.	Metin, görüntü, video, ses, sosyal medya içerikleri vb.
Erişim ve Analiz	Standart sorgu dilleri (SQL vb.) ile kolayca erişilip analiz edilebilir.	Gelişmiş veri işleme teknikleri, yapay zekâ ve NLP gerektirir.
Örnekler	Finansal tablolar, müşteri bilgileri, satış kayıtları, stok yönetimi verileri.	E-posta içerikleri, sosyal medya paylaşımları, tıbbi görüntüler, multimedya dosyaları.
Veri İşleme	Yapılandırılmış kurallar çerçevesinde işlenebilir, otomatik analiz edilebilir.	Büyük veri analitiği, ML ve DL teknikleri gerektirir.

Esneklik	Daha az esnektir, belirli formatlarda saklanmak zorundadır.	Daha esnektir, farklı formatlarda saklanabilir ve işlenebilir.
Ölçeklenebilirlik	Geleneksel veri tabanlarında ölçeklenmesi daha sınırlıdır.	Dağıtık veri işleme sistemleri ile daha iyi ölçeklenebilir.

Yapılandırılmış veri, belirli bir format içinde düzenlenmiş olup, ilişkisel veri tabanlarında saklanarak kolay erişim ve analiz imkânı sunmaktadır (Siddiqa vd., 2017). Buna karşın, yapılandırılmamış veri belirli bir düzene sahip olmadığı için büyük veri platformları ve dağıtık sistemlerde işlenmekte (Liu vd., 2016), bu da esneklik sağlarken analiz sürecini daha karmaşık hale getirmektedir. Yapılandırılmış veriler genellikle SQL tabanlı sistemlerde depolanırken, yapılandırılmamış veriler NLP, görüntü işleme ve ML gibi ileri düzey tekniklerle analiz edilmektedir.

YZ-KDS bünyesinde zaman serisi analizleri, regresyon modelleri ve olasılık tabanlı yaklaşımlar, çeşitli sektörlerde talep tahmini, finansal risk analizi ve operasyonel verimlilik değerlendirmeleri için yaygın olarak kullanılmaktadır. Zaman serisi analizleri ve regresyon modelleri, piyasa dalgalanmalarından operasyonel süreçlere kadar geniş bir yelpazede veri odaklı içgörüler sunarken, DL tabanlı sistemler çok boyutlu veri ilişkilerini keşfederek daha karmaşık problemlere çözüm üretmektedir. Bu sistemler, önceden tanımlı tahminleme yaklaşımlarının aksine, belirsizlikleri minimize etmek için anomali tespiti, duyarlılık analizi ve senaryo simülasyonları gibi ileri tekniklerden yararlanmaktadır (Villano vd., 2024). Böylece, organizasyonlar yalnızca kısa vadeli tahminler yapmakla kalmayıp, aynı zamanda uzun vadeli stratejilerini değişen pazar dinamiklerine uyum sağlayacak şekilde şekillendirebilmektedir (Olukoya, 2023). Tedarik zinciri yönetimi, finansal risk analizi ve müşteri davranış tahminleri gibi kritik alanlarda, YZ-KDS, insan müdahalesine duyulan ihtiyacı azaltarak daha hızlı ve doğru kararların alınmasına olanak tanımaktadır.

Otomasyon yeteneği, YZ-KDS'nin en temel işlevlerinden biri olup, karar alma süreçlerini hızlandırarak operasyonel verimliliği artırmaktadır. Geleneksel KDS'ler, büyük ölçüde kural tabanlı çalıştığından manuel müdahale gerektirmekte ve süreçlerin yürütülmesinde insan faktörüne bağımlılık oluşturmaktadır. YZ tabanlı otomasyon süreçleri, veri analitiğini gerçek zamanlı olarak gerçekleştirerek anlık değişimleri takip edebilme ve bu değişimlere uygun karar önerileri sunabilmektedir. Büyük veri teknolojileri ile bütünleşik çalışan bu sistemler, veri akışlarını sürekli izleyerek belirli eşik değerleri ve örüntüler üzerinden anormallik tespiti yapabilmekte ve karar

vericilere uyarılar oluşturabilmektedir (Goswami, 2024). KDS, örüntü tanıma ve istatistiksel modelleme yöntemleri sayesinde, manuel olarak tespit edilmesi güç olan ilişkilere ve eğilimlere odaklanarak daha doğru ve veri odaklı karar önerileri sunmaktadır (Safdar vd., 2018). Otomasyonun bir diğer kritik yönü, süreçlerin özerk hale gelmesini sağlayarak karar alma mekanizmalarında insan hatasını minimize etmesidir. İnsan kaynaklı hatalar, bilişsel önyargılar, dikkatsizlik veya veri setlerindeki eksiklikler nedeniyle oluşabilmektedir (Morais vd., 2022). YZ destekli sistemler, karar süreçlerini istatistiksel modeller ve algoritmalar aracılığıyla yönettiğinden, nesnel ve tutarlı bir analiz süreci sunarak hataları en aza indirmektedir. Ancak, otomasyon süreçlerinin güvenilirliği, kullanılan verinin doğruluğu ve sistemin eğitildiği modellerin kalitesi ile doğrudan ilişkilidir (Sarker, 2022). Bu nedenle, model güncellemeleri ve performans izleme süreçleri, otomatik karar alma mekanizmalarının doğruluğunu sağlamak için bir gereklilik haline gelmektedir. YZ-KDS, farklı senaryoları simüle edebilme yeteneği sayesinde risk yönetimi ve senaryo analizi gibi alanlarda da önemli bir avantaj sağlamaktadır. Otomasyon süreçleri, belirsizlik altındaki kararların modellenmesine ve olasılıksal analizlerin gerçekleştirilmesine olanak tanıyarak, organizasyonların proaktif karar alma kabiliyetini artırmaktadır (Van Rijmenam vd., 2019). Ancak, sistemlerin adaptasyon yeteneği, kullanılan algoritmaların genel yapısı ve güncellenme sıklığı ile doğrudan bağlantılıdır (Gong vd., 2021). Algoritmaların değişen koşullara hızla uyum sağlayabilmesi için sürekli geri bildirim mekanizmalarının uygulanması ve sistemlerin dinamik öğrenme süreçleri ile desteklenmesi gerekmektedir.

YZ-KDS'nin uygulanmasında karşılaşılan en önemli teknik zorluklardan biri model şeffaflığı ve yorumlanabilirliğidir. DL tabanlı sistemler, karmaşık çokkatmanlı sinir ağları ve büyük boyutlu parametre kümeleri ile çalıştığından, elde edilen tahminlerin nasıl üretildiğini anlamak zorlaşmaktadır. Bu tür sistemlerde kullanılan ileri seviye modelleme teknikleri, büyük miktarda veriyi işleyerek oldukça yüksek doğrulukta sonuçlar üretebilse de bu modellerin iç işleyiş mekanizmaları, insan karar vericiler açısından bir "kara kutu" niteliği taşımaktadır. Modelin girdi değişkenleri ile çıktı arasındaki ilişki, doğrusal olmayan ve yüksek derecede parametrik fonksiyonlar üzerinden hesaplandığından, belirli bir kararın hangi faktörlere dayanarak verildiğini doğrudan görmek mümkün olmayabilmektedir (Hassija vd., 2024). Model şeffaflığının sağlanamaması, sistemlerin güvenilirliği ve hesap verebilirliği açısından çeşitli riskler yaratmaktadır. Ayrıca, modelin karar üretme süreci anlaşılabilir olmadığından, ortaya çıkan hatalar veya önyargılar fark edilmeden sistem tarafından tekrarlanabilmekte, bu da sistematik hata riskini artırabilmektedir (Berber ve Srećković, 2024). Bu teknik



zorlukların üstesinden gelmek amacıyla XAI yöntemleri geliştirilmektedir. Açıklanabilirlik teknikleri, modelin aldığı kararların nedenlerini daha anlaşılır hale getirmeyi amaçlamakta ve belirli bir tahminin hangi faktörler doğrultusunda oluşturulduğunu matematiksel olarak analiz edebilme olanağı sunmaktadır (Minh vd., 2022). Bu bağlamda, model şeffaflığını artırmak için çeşitli post-hoc analiz yöntemleri, duyarlılık analizleri ve karar ağaçları gibi teknikler uygulanmaktadır (Gill vd., 2020). Açıklanabilirlik mekanizmaları, modelin girdiler ve çıktılar arasındaki ilişkileri daha açık hale getirmekle kalmayıp, aynı zamanda sistemlerin hata ayıklama süreçlerini kolaylaştırarak performans optimizasyonuna da katkı sağlamaktadır. Regülasyonlara tabi sektörlerde, model açıklanabilirliği daha da kritik bir hale gelmektedir (Lisboa vd., 2023). Finans, sağlık ve hukuk gibi alanlarda, yapay zekâ destekli kararların yasal ve etik açıdan hesap verebilir olması gerekmekte, bu nedenle kullanılan modellerin karar verme süreçlerinin açık ve denetlenebilir olması beklenmektedir. Bu doğrultuda, geliştirilen XAI yaklaşımları, düzenleyici kurumların belirlediği kriterlere uygun şekilde model şeffaflığını sağlamakta ve sistemlerin kabul edilebilirliğini artırmaktadır. Ancak, açıklanabilirlik ile modelin tahmin gücü arasında belirli bir denge bulunması gerektiği unutulmamalıdır. Daha kompleks modeller genellikle daha yüksek doğruluk sunarken, aynı zamanda daha az yorumlanabilir hale gelmektedir (Li vd., 2022). Bu nedenle, YZ-KDS'de model seçimi yapılırken hem performans hem de şeffaflık kriterleri dikkate alınarak, sistemlerin güvenilir ve sürdürülebilir bir şekilde çalışması sağlanmalıdır.

Veri kalitesinin ve bütünlüğünün sağlanması, YZ-KDS başarısını doğrudan belirleyen temel unsurlardan biridir. YZ destekli sistemlerin analitik yetkinlikleri, büyük ölçüde kullanılan verinin doğruluğu, tutarlılığı, eksiksizliği ve güncelliği ile ilişkilidir (Badmus vd., 2024). Veri setlerinde bulunan tutarsızlıklar, eksiklikler veya yanlış etiketlemeler, modelin eğitimi sürecinde yanlış örüntülerin öğrenilmesine yol açarak, tahmin performansını olumsuz yönde etkileyebilmektedir. Bunun sonucunda, model tarafından üretilen tahminler hatalı olabilmekte ve karar destek mekanizmaları yanlış yönlendirilebilmektedir. Bu tür hataların en aza indirilebilmesi için, veri işleme süreçlerinde sistematik doğrulama mekanizmalarının uygulanması ve istatistiksel analiz yöntemleriyle verinin güvenilirliğinin sağlanması gerekmektedir. Veri temizleme süreçleri, yapay zekâ modellerinin eğitimi öncesinde ve çalışma aşamasında uygulanması gereken temel veri yönetim tekniklerinden biridir. Bu süreçte, anomali tespiti algoritmaları ve istatistiksel analiz yöntemleri kullanılarak verinin içeriğindeki hatalar, çelişkili bilgiler ve eksik değerler belirlenmeli, düzeltilmeli veya uygun yöntemlerle işlenmelidir. Eksik verilerin tamamlanması sürecinde regresyon analizleri,

çoklu girişimleme (multiple imputation) teknikleri veya istatistiksel yeniden örnekleme yöntemleri gibi yaklaşımlar kullanılabilir (Yu vd., 2020). Ayrıca, verinin aşırı uç değerlere (outlier) sahip olup olmadığı belirlenmeli ve modelin doğruluğunu artırmak amacıyla gerekli filtreleme işlemleri gerçekleştirilmelidir (Zhu vd., 2018). Veri bütünlüğü, birden fazla kaynaktan elde edilen bilgilerin tutarlı olması, farklı veri kümeleri arasında uyum sağlanması ve zaman içerisinde değişen veri yapılarının sistemin öğrenme sürecine zarar vermeyecek şekilde işlenmesi anlamına gelmektedir (Kahn vd., 2016). Büyük ölçekli veri yönetim sistemlerinde, farklı veri kaynaklarından gelen bilgilerin standardize edilmesi ve çelişkili veri girişlerinin belirlenerek düzeltilmesi, sistemlerin doğruluğunu artırmak açısından büyük önem taşımaktadır. Ayrıca, merkezi ve dağıtık veri yönetimi sistemlerinde veri bütünlüğünü sağlamak amacıyla belirli protokollerin ve doğrulama kurallarının oluşturulması gerekmektedir (Hang ve Kim, 2019). YZ-KDS’de, kullanılan verinin sürekli olarak güncellenmesi ve değişen koşullara uyum sağlaması da önemli bir gerekliliktir. Modelin eğitim aşamasında kullanılan veri dağılımı zaman içinde değişebilir ve bu durum modelin doğruluğunu olumsuz etkileyebilmektedir (Maharana vd., 2022). Bu olgu, “concept drift” olarak adlandırılmakta olup, modelin geçmiş veriye dayalı öğrendiği örüntülerin artık geçerli olmamasıyla sonuçlanabilmektedir (Lu vd., 2018). Concept drift’in etkilerini en aza indirmek için, veri güncelleme süreçlerinin belirli aralıklarla gerçekleştirilmesi, yeni verilerle modelin yeniden eğitilmesi ve değişen veri dağılımlarına uyum sağlayabilen dinamik öğrenme mekanizmalarının geliştirilmesi gerekmektedir. Sürekli öğrenen sistemlerin tasarlanması, modelin doğruluğunun korunmasını ve karar destek mekanizmalarının değişen koşullara uyum sağlamasını mümkün kılmaktadır.

Ölçeklenebilirlik ve işlem gücü gereksinimleri, YZ-KDS teknik kısıtları arasında önemli bir yer tutmaktadır. YZ tabanlı sistemlerin etkin çalışabilmesi için büyük miktarda verinin yüksek hızda işlenmesi ve analiz edilmesi gerekmektedir. DL tabanlı modeller yüksek işlem gücüne ihtiyaç duymaktadır. Büyük veri kümelerinin işlenmesi, model eğitimi ve çıkarım süreçlerinin etkin bir şekilde yürütülebilmesi için yüksek işlem kapasitesine sahip donanımların yanı sıra, ölçeklenebilir yazılım ve altyapı çözümlerinin geliştirilmesi gerekmektedir (Asch vd., 2018). Aksi takdirde, işlem sürelerinde meydana gelen gecikmeler, karar süreçlerinin zamanında tamamlanmasını engelleyebilmekte ve sistemlerin gerçek zamanlı veri akışına uyum sağlamasını zorlaştırabilmektedir (Tien, 2017). YZ-KDS’de işlem gücü gereksinimlerinin karşılanabilmesi için öncelikle paralel hesaplama yöntemlerinin etkin şekilde uygulanması gerekmektedir. Merkezi işlem birimleri (CPU) sınırlı sayıda

iş parçacığıyla çalıştığından, bu tür sistemlerde veri paralellliğini ve işlem verimliliğini artırmak amacıyla grafik işlem birimleri (GPU) ve tensör işlem birimleri (TPU) gibi özel donanımların kullanımı yaygınlaşmaktadır (Jouppi vd., 2017). GPU'lar, çok sayıda işlem çekirdeğine sahip olmaları sayesinde, büyük ölçekli matris hesaplamaları ve tensör işlemleri gibi yoğun hesaplama gerektiren görevleri yüksek hızda gerçekleştirebilmekte ve YZ modellerinin eğitimi için kritik bir rol oynamaktadır (Liu vd., 2022). Bununla birlikte, yüksek işlem gücü gerektiren sistemlerin verimli çalışabilmesi için bellek yönetimi, veri aktarım hızları ve sistem mimarisi gibi unsurların da dikkate alınması gerekmektedir (Zhang vd., 2015). Bellek kapasitesinin yetersiz olması veya veri aktarım hızlarının düşük olması, model eğitim sürelerini uzatarak sistem performansını olumsuz yönde etkileyebilmektedir.

Dağıtık hesaplama teknikleri, YZ-KDS'de ölçeklenebilirliği artırmak için kullanılan bir diğer önemli yöntemdir. Büyük veri kümelerinin işlenmesi ve model eğitimi süreçlerinin hızlandırılması amacıyla, verilerin birden fazla düğüme bölünerek eş zamanlı işlenmesini sağlayan dağıtık veri işleme sistemleri yaygın olarak kullanılmaktadır. Yüksek hacimli veri analitiği için geliştirilen MapReduce ve Apache Spark gibi çerçeveler, veri işleme süreçlerini paralel hale getirerek hesaplama verimliliğini artırmakta ve sistemlerin büyük ölçekli veri akışlarına uyum sağlamasını kolaylaştırmaktadır (Singh vd., 2018). Ancak, dağıtık sistemlerin verimli bir şekilde çalışabilmesi için veri iletişim maliyetlerinin ve düğümler arasındaki senkronizasyon mekanizmalarının etkin bir şekilde yönetilmesi gerekmektedir (Ge vd., 2017). Veri paylaşım süreçlerinde yaşanan gecikmeler veya düğümler arasında meydana gelen uyumsuzluklar, hesaplama süreçlerinde darboğazlara neden olarak performans kayıplarına yol açabilmektedir (Liu vd., 2017). Bunun yanı sıra, YZ-KDS'lerin ölçeklenebilirliği açısından bulut bilişim altyapılarının kullanımı giderek yaygınlaşmaktadır. Bulut bilişim platformları, esnek kaynak tahsisi ve yüksek işlem kapasitesi sunarak, büyük ölçekli hesaplama gereksinimlerine sahip sistemlerin maliyet etkin bir şekilde çalıştırılmasını sağlamaktadır (Hameed vd., 2016). Bulut tabanlı çözümler, organizasyonların ihtiyaca göre dinamik olarak işlem gücü ve depolama kapasitesini ölçeklendirmesine olanak tanımakta ve büyük veri analitiği için gerekli altyapıyı esnek bir şekilde sunmaktadır. Bununla birlikte, bulut tabanlı sistemlerin kullanımı, veri güvenliği, gecikme süreleri ve operasyonel maliyetler gibi faktörleri de beraberinde getirmektedir. Hassas veri içeren sistemlerde, veri transfer süreçlerinin güvenliğinin sağlanması ve işlenen verilerin mahremiyetini koruyan tekniklerin uygulanması önem taşımaktadır (Sun, 2019).

Veri güvenliği ve gizliliği, YZ-KDS uygulanabilirliği açısından kritik bir faktördür. Büyük veri analitiği temelli çalışan bu sistemler, yüksek hacimli ve çeşitli veri kaynaklarından gelen bilgileri işleyerek karar alma süreçlerini desteklemektedir. Ancak, bu süreçte işlenen veriler arasında hassas, gizli veya kişisel bilgiler bulunabileceğinden, veri güvenliği açıkları ve yetkisiz erişim riskleri ciddi tehditler oluşturmaktadır. Bu nedenle, YZ-KDS'lerin güvenliğini sağlamak amacıyla kapsamlı bir güvenlik mimarisi oluşturulmalı ve veri koruma stratejileri çok katmanlı bir yaklaşımla ele alınmalıdır. Veri güvenliği mekanizmaları, yalnızca dış saldırılara karşı koruma sağlamakla kalmayıp, aynı zamanda organizasyon içindeki yetkisiz erişimleri ve veri manipülasyonunu önleyecek şekilde tasarlanmalıdır. Yetkisiz erişimlerin engellenmesi ve veri güvenliğinin sağlanması için güçlü kimlik doğrulama ve erişim kontrol mekanizmalarının uygulanması gerekmektedir. Bu kapsamda, rol tabanlı erişim kontrolü (Role-Based Access Control - RBAC) ve yetkilendirilmiş erişim politikaları gibi yöntemler, kullanıcıların yalnızca belirlenen yetkiler dâhilinde verilere erişebilmesini sağlayarak veri bütünlüğünü korumaktadır (Saxena ve Alam, 2023). Ayrıca, MFA gibi güvenlik protokollerinin uygulanması, yetkisiz girişleri engelleyerek sistemin saldırılara karşı dayanıklılığını artırmaktadır. Erişim kontrolü ile sistem üzerindeki tüm veri hareketlerinin ve kullanıcı aktivitelerinin kayıt altına alınması da güvenlik ihlallerini tespit etmek ve sistemin güvenilirliğini artırmak açısından önemli bir gerekliliktir (Salman vd., 2018). Veri şifreleme teknikleri, YZ-KDS'lerin güvenliğini sağlamada önemli bir başka bileşendir. Ancak, güçlü şifreleme yöntemleri kullanılsa dahi, veri işleme süreçlerinde açığa çıkan bilgilerin kötüye kullanılmasını önlemek amacıyla veri bütünlüğü doğrulama mekanizmaları ile güvenlik önlemleri tamamlanmalıdır.

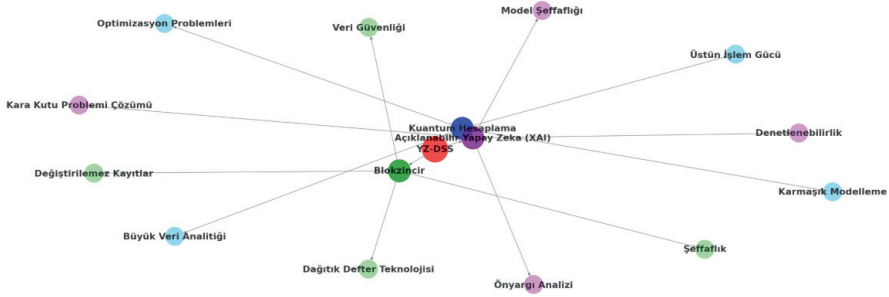
Büyük veri analitiği ile çalışan KDS'lerin gizlilik risklerini minimize etmek için anonimleştirme teknikleri önemli bir rol oynamaktadır. Kişisel verilerin işlendiği sistemlerde, kimlik tanımlayıcı bilgiler anonim hale getirilerek bireylerin mahremiyeti korunmalıdır. K-anonimlik, farklılaştırılmış gizlilik ve veri maskeleye gibi anonimleştirme teknikleri, verinin analiz edilebilirliğini korurken, bireylerin doğrudan teşhis edilmesini engelleyerek veri gizliliğini sağlamaktadır (Wang vd., 2018). Ancak, anonimleştirme tekniklerinin etkinliği, kullanılan yöntem ve veri setinin yapısına bağlı olduğundan, yanlış uygulanması durumunda verinin tekrar tanımlanabilir hale gelmesi gibi riskler ortaya çıkabilmektedir (Eze ve Peyton, 2015). Bu nedenle, anonimleştirme yöntemleri dikkatli bir şekilde tasarlanmalı ve sürekli güncellenmelidir. Bunların yanı sıra, YZ-KDS'lerin kullanımında etik ve yasal düzenlemeler de önemli bir konu olarak öne çıkmaktadır. Büyük veri analitiği ile yapılan işlemler, kişisel verilerin korunmasını düzenleyen

ulusal ve uluslararası regülasyonlara uygun olarak yürütülmelidir. GDPR ve benzeri düzenlemeler, kişisel verilerin korunması ve veri sahiplerinin haklarının güvence altına alınması için organizasyonların uyması gereken kuralları belirlemektedir (Tikkinen-Piri vd., 2018). Bu tür düzenlemelere uyumsuzluk, hukuki yaptırımlara yol açabileceği gibi, organizasyonların itibar kaybına uğramasına da neden olabilmektedir. Bu bağlamda, veri güvenliği ve gizliliği konusunda güçlü bir strateji belirlemek, yalnızca teknik önlemlerle sınırlı kalmayıp, aynı zamanda organizasyonel politikalar ve düzenleyici çerçeveler doğrultusunda sistemin bütüncül bir yaklaşımla yönetilmesini gerektirmektedir.

YZ-KDS'ler, veri analitiği, tahmine dayalı analitik, otomasyon ve ölçeklenebilirlik açısından birçok avantaj sunarken, model şeffaflığı, veri güvenliği, işlem gücü gereksinimleri ve teknik yönetim zorlukları gibi faktörler, bu sistemlerin etkin kullanımını kısıtlayabilmektedir. Bu sistemlerin daha güvenilir, şeffaf ve verimli hale gelmesi için sürekli iyileştirme çalışmaları yapılmalı ve gelişen yapay zekâ teknikleri ile bu zorluklar aşılmalıdır.

## 6. KDS'lerde Gelecek Trendler

KDS, teknolojik ilerlemelerle birlikte giderek daha bütünleşmiş, akıllı ve özerk hâle gelmekte, karar vericilere yalnızca geçmiş veriye dayalı analizler sunmanın ötesine geçerek stratejik öngörüler ve proaktif aksiyon önerileri sağlamaktadır. Büyük veri analitiği, ML, DL, blokzincir ve kuantum hesaplama gibi yenilikçi teknolojiler, KDS'nin analiz kapasitesini ve çevresel değişkenleri anlamlandırma yetkinliğini genişletirken, sistemlerin gerçek zamanlı ve tahmine dayalı karar süreçlerinde daha etkin roller üstlenmesini mümkün kılmaktadır. Bunun yanı sıra, yapay zekâ tabanlı modellerin artan kullanımını, güvenlik, etik ve düzenleyici çerçevelerin yeniden değerlendirilmesini zorunlu kılmakta, şeffaf ve denetlenebilir karar mekanizmalarının geliştirilmesini gerektirmektedir. Bu bağlamda, KDS'nin geleceğini şekillendiren temel eğilimler, zayıf sinyallerin tespiti ve erken aşama tahminleme, çok değişkenli optimizasyon süreçlerinin otomatikleştirilmesi, bağlamsal anlamlandırma ve proaktif karar mekanizmaları ile güvenlik, etik ve düzenleyici çerçevelerin yeniden tanımlanması başlıkları altında incelenebilir. KDS'nin geleceğine yönelik bu teknolojik gelişmelerin birbirleriyle nasıl etkileşime geçtiği ve YZ-KDS üzerindeki etkileri Şekil 2'de kavramsal olarak gösterilmiştir.



Şekil 2. YZ-KDS Üzerindeki Gelecek Teknolojilerin Etkisi

## 6.1. Zayıf Sinyallerin Tespiti ve Erken Aşama Tahminleme

Yeni nesil KDS'ler, zayıf sinyallerin tespiti (weak signal detection) ve olayların erken aşamada tahmin edilmesi (early warning detection) gibi gelişmiş yeteneklere sahip olacak şekilde evrilmektedir. Zayıf sinyaller, gelecekte büyük etkiler yaratabilecek ancak henüz belirgin hâle gelmemiş küçük ve düşük yoğunluklu veriler ya da göstergeler olarak tanımlanabilir. Geleneksel sistemler, çoğunlukla güçlü ve belirgin sinyaller üzerinden çalıştığından, bu küçük ölçekli değişimleri tespit edememekte veya ihmal edebilmektedir. Ancak, YZ, ML ve DL tabanlı algoritmalar, büyük miktarda veriyi sürekli analiz ederek bu zayıf sinyalleri tespit edebilir ve gelecekte büyük etkilere yol açabilecek gelişmeleri önceden öngörebilir. Bu gelişim, risk yönetimi, finansal karar alma, sağlık hizmetleri yönetimi ve tedarik zinciri optimizasyonu gibi alanlarda büyük bir dönüşüm yaratacaktır. Finansal piyasalar için geliştirilen bir KDS, yalnızca geçmiş fiyat hareketlerini analiz etmekle kalmayacak, aynı zamanda piyasa psikolojisini, yatırımcı duyarlılığını ve küresel ekonomik dinamikleri değerlendirerek olası krizleri öngörebilecektir. Sağlık sektöründe kullanılan bir KDS, hastaların genetik verilerini, yaşam tarzı tercihlerini ve çevresel faktörleri analiz ederek kişiselleştirilmiş tedavi planları öneren bir yapıya dönüşecektir. Tedarik zinciri yönetiminde, lojistik süreçleri optimize eden bir KDS, hava durumu tahminleri, siyasi istikrarsızlık göstergeleri ve üretim kapasitesine dair verileri analiz ederek tedarik zinciri aksamalarını önceden tespit edebilecektir.

## 6.2. Çok Değişkenli Optimizasyon Süreçlerinin Otomatikleştirilmesi

KDS, çok değişkenli optimizasyon süreçlerini otomatikleştirerek karar mekanizmalarının hızını, doğruluğunu ve adaptasyon yeteneğini artırmaktadır. Kural tabanlı sistemler genellikle belirli kriterlere odaklanarak

tekil deęişkenler üzerinden öneriler sunarken, yeni nesil KDS'ler birden fazla parametreyi eşzamanlı olarak analiz ederek karmaşık ve dinamik koşullar altında en iyi çözümleri belirleyebilen mekanizmalara dönüşecektir. Bu dönüşüm, belirsizliklerin yoğun olduğu, deęişkenlerin birbirleriyle etkileşim içinde olduğu senaryolarda karar alıcılar için büyük avantajlar sağlayacaktır. Gerçek dünyadaki karar problemleri çoęu zaman birbiriyle doğrudan veya dolaylı olarak ilişkili birçok faktörü içermektedir (Bettis, 2017). Örneęin, bir işletmenin tedarik zinciri yönetiminde maliyetleri minimize etmek, teslimat sürelerini kısaltmak ve müşteri memnuniyetini artırmak gibi hedefler birbirleriyle çelişebilecek dinamikler yaratabilir. Benzer şekilde, finansal portföy yönetiminde, yatırım getirilerini maksimize ederken risk seviyesini belirli bir eşiğin altında tutmak gibi birbirine baęlı ve optimize edilmesi gereken deęişkenler bulunmaktadır. Yeni nesil KDS, geleneksel kural tabanlı analiz yöntemlerinden farklı olarak yapay zekâ, ML, büyük veri analitięi, kuantum hesaplama ve gerçek zamanlı veri işleme gibi ileri teknolojileri entegre ederek dinamik ve otonom karar alma süreçlerini desteklemektedir (Simuni vd., 2024). Bu sistemler, çok deęişkenli optimizasyon, pekiştirmeli öğrenme, DL, tahmine dayalı analitik ve federatif öğrenme gibi teknikleri kullanarak hem operasyonel hem de stratejik karar süreçlerini sürekli iyileştirmektedir.

### 6.3. Derin Pekiştirmeli Öğrenme ile Adaptif KDS

Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning - DRL), dinamik karar ortamlarında sürekli öğrenme ve adaptasyon yeteneęi sağlayarak YBS içinde kritik bir bileşen hâline gelmektedir. DRL çevresel deęişkenleri sürekli gözlemleyerek ve etkileşimler sonucunda ödöl-maliyet dengesini optimize ederek karar süreçlerini iyileştirmektedir (Chu vd., 2024). Bu süreç, Markov Karar Süreçleri (Markov Decision Processes - MDP) temelinde modellenmekte ve durum-eylem-ödöl geçişleri ile sistemin karar verme yetkinlięi zaman içinde güçlenmektedir (He vd., 2020). YBS kapsamında, proksimal politika optimizasyonu (PPO), avantajlı aktör-eleştirmen yöntemleri (Advantage Actor-Critic - A2C, A3C) ve derin Q-aęları (Deep Q-Network - DQN) gibi DRL teknikleri, karmaşık operasyonel süreçlerin optimizasyonunda kullanılarak KDS'nin reaktif deęil, proaktif hâle gelmesine olanak tanımaktadır. Tedarik zinciri yönetimi, üretim planlaması, finansal tahminleme ve müşteri ilişkileri yönetimi gibi alanlarda DRL'nin sunduęu özyinelemeli (iteratif) karar mekanizmaları, deęişken pazar koşulları, talep dalgalanmaları ve operasyonel kısıtlar doğrultusunda en uygun stratejileri belirlemektedir. Çok kollu bandit algoritmaları (Multi-Armed Bandit - MAB) ve Bayes optimizasyonu, tedarik zincirindeki

çok değişkenli optimizasyon problemlerinin çözümüne katkı sağlayarak talep dalgalanmalarına karşı dayanıklı ve esnek stok yönetimi stratejileri geliştirilmesini mümkün kılmaktadır (Bastani vd., 2022). Finansal yönetim alanında, DRL ile güçlendirilmiş KDS çözümleri, risk yönetimi, portföy optimizasyonu ve kredi skorlama gibi süreçlerde öğrenen ve kendini uyarlayan yatırım stratejileri oluşturmaktadır. Monte Carlo simülasyonları ile entegre edilen derin Q-ağları (Das ve Varma, 2020), fiyat tahmini ve piyasa oynaklığı analizlerinde kullanılarak finansal belirsizliklerin daha hassas modellenmesini sağlama potansiyelindedir. YBS içindeki müşteri ilişkileri yönetimi (CRM) ve kişiselleştirilmiş pazarlama süreçlerinde, DRL tabanlı sistemler, kullanıcı davranışlarını sürekli analiz ederek ve öğrenme sürecini güncelleyerek, müşteri etkileşimlerini en üst düzeye çıkaracak otomatik öneri mekanizmaları geliştirmektedir. Örneğin, e-ticaret platformlarında dinamik fiyatlandırma ve reklam öneri sistemleri, DRL'nin sağladığı büyük veri analitiği ve sezgisel optimizasyon teknikleri ile kişiselleştirilmiş müşteri deneyimleri oluşturabilmektedir.

#### **6.4. Çevik ve Özerk KDS**

Gerçek zamanlı veri işleme, büyük ölçekli veri setlerinin düşük gecikme süresiyle işlenmesini sağlayarak YBS kapsamında hızlı, ölçeklenebilir ve otomatik karar mekanizmalarının oluşturulmasına olanak tanımaktadır. Toplu (batch) veri işleme sistemleri, veriyi belirli aralıklarla işleyerek analiz süreçlerinde gecikmelere yol açarken, gerçek zamanlı veri akışı işleme (stream processing), akış hâlinde gelen veriyi sürekli analiz etmektedir (Tantalaki vd., 2020). Bu bağlamda, Apache Kafka, Apache Flink ve Apache Spark Streaming gibi dağıtık veri işleme çerçeveleri, yüksek hacimli veri akışlarını zaman serisi analizi, olay güdümlü (event-driven) sistemler ve anomali tespiti gibi kritik süreçlerde kullanarak KDS'yi çevik ve proaktif hâle getirmektedir (Alam vd., 2024). Kafka, yüksek verimlilikle ölçeklenebilir bir yayınla-abone ol (publish-subscribe) modeli sunarak, dağıtık sistemler arasında güvenilir ve hataya dayanıklı veri aktarımı sağlarken, Apache Flink, düşük gecikmeli ve durum bilgili (stateful) işlem motoru ile akış hâlindeki veriyi gerçek zamanlı olarak analiz edebilmektedir. Apache Spark Streaming ise mikro-toplu işleme (micro-batching) tekniğiyle, gerçek zamanlı analitik yeteneklerini geniş ölçekli dağıtık veri kümelerinde etkin bir şekilde uygulamaktadır. Kenar bilişim (Edge Computing), gerçek zamanlı veri işlemeyi merkezi bulut sunucularına olan bağımlılığı azaltarak ağ üzerindeki uç noktalarda (IoT cihazları, sensörler, akıllı terminaller) gerçekleştirilen işlem gücünü artırmaktadır (Ning vd., 2020). Geleneksel bulut bilişim modellerinde, veriler uzak veri merkezlerine gönderilip işlendiğinden, gecikmeye duyarlı



uygulamalar için performans kayıpları yaşanmaktadır. Edge bilişim yaklaşımı, veriyi üretildiği noktada işleyerek gecikmeyi düşürmekte, ağ trafiğini azaltmakta ve işlem sürekliliğini artırmaktadır (Singh vd., 2019). YBS içinde tedarik zinciri yönetimi, akıllı üretim sistemleri ve siber-fiziksel sistemler, kenar bilişim destekli gerçek zamanlı veri işleme ile otomatik ve özerk karar alma yetkinliğine kavuşmaktadır. Örneğin, üretim hatlarında yer alan IoT sensörleri, üretim süreçlerindeki anlık dalgalanmaları tespit ederek kestirimci bakım (predictive maintenance) algoritmalarını çalıştırabilir ve potansiyel arızaları önceden öngörerek üretim verimliliğini artırabilir. Perakende sektöründe ise gerçek zamanlı müşteri davranış analizi sayesinde dinamik fiyatlandırma, stok optimizasyonu ve kişiselleştirilmiş pazarlama stratejileri geliştirilebilmektedir. Finansal yönetim ve siber güvenlik alanlarında da gerçek zamanlı veri işleme, olağandışı işlemleri anında tespit ederek sahtekarlık önleme (fraud detection) mekanizmalarını güçlendirmektedir. ML ile entegre edilen akış işleme sistemleri, şüpheli işlem kalıplarını sürekli analiz ederek anomalileri tanımlamakta ve dinamik tehdit önleme stratejileri geliştirmektedir.

### 6.5. Kuantum Hesaplama ile Optimize Edilmiş KDS

Kuantum hesaplama (Quantum Computing), geleneksel optimizasyon yöntemlerinin hesaplama gücü ve zaman açısından karşılaştığı sınırlamaları aşarak, yüksek boyutlu karar değişkenleri içeren karmaşık problemlerin çözüm sürecini hızlandırmaktadır. Kuantum mekaniği prensiplerine dayanan bu yaklaşım, süperpozisyon ve dolanıklık gibi özellikler sayesinde klasik bilgisayarlara kıyasla üstel bir hız artışı sağlayarak, büyük ölçekli veri kümeleri üzerinde etkili hesaplamalar gerçekleştirmektedir (Erhard vd., 2020). YBS kapsamında KDS için kuantum hesaplamanın optimizasyon ve tahmin süreçlerindeki rolü giderek artmaktadır. Kuantum annealing ve varyasyonel kuantum algoritmaları (Variational Quantum Algorithms - VQA) gibi yaklaşımlar, büyük ölçekli kombinatoriyal optimizasyon problemlerinin çözümünü klasik yöntemlere kıyasla önemli ölçüde hızlandırmaktadır (Cerezo vd., 2021). Kuantum annealing, D-Wave gibi kuantum donanımlarında uygulanan ve özellikle NP-zor (NP-hard) optimizasyon problemlerini çözen bir yöntemdir. Bu teknik, enerji minimizasyonu prensibine dayanarak en uygun çözümü bulmak için kuantum tünelleme özelliğinden faydalanmaktadır (Yarkoni vd., 2022). VQA ise klasik ve kuantum hesaplamayı hibrit bir yapıda birleştirerek, parametrik kuantum devrelerini optimizasyon süreçlerinde kullanmaktadır. Finans sektöründe, Monte Carlo simülasyonları, portföy optimizasyonu ve kredi riski analizi gibi işlemler, klasik bilgisayarların sınırlı işlem kapasitesi nedeniyle hesaplama açısından büyük zorluklar içermektedir.

Kuantum hesaplama, olasılık dağılımlarını çok daha verimli bir şekilde simüle ederek risk analizlerini daha hassas hâle getirmekte ve finansal tahmin modellerini geliştirmektedir. Örneğin, Black-Scholes modeli gibi türev ürün fiyatlandırma algoritmaları (Zhang vd., 2024), kuantum hesaplama ile daha hızlı çalıştırılabilir, risk ölçümleri daha etkin bir şekilde optimize edilebilir. Tedarik zinciri yönetiminde, çok değişkenli optimizasyon gerektiren lojistik planlama, stok yönetimi ve rota optimizasyonu gibi süreçlerde kuantum hesaplama, büyük veri kümeleri üzerinde paralel hesaplamalar yaparak en uygun stratejilerin belirlenmesini sağlamaktadır. Örneğin, bir şirketin küresel tedarik zinciri içinde en düşük maliyetli ve en hızlı teslimat rotalarını belirlemek için çözmesi gereken optimizasyon problemleri, geleneksel yöntemlerle uzun süreler alırken, kuantum algoritmaları sayesinde anlık olarak optimize edilebilmektedir. Üretim sektöründe, kuantum hesaplama destekli kestirimci bakım (predictive maintenance) sistemleri, büyük ölçekli sensör verilerini analiz ederek arızaları önceden tespit etmekte ve üretim süreçlerini kesintisiz hâle getirmektedir (Sharma vd., 2024). ML tabanlı hata tespiti süreçlerinde, kuantum algoritmaları, klasik istatistiksel analiz tekniklerinden çok daha yüksek doğrulukta tahminler yaparak, ekipman arızalarını önceden öngörebilmektedir.

## 6.6. Büyük Dil Modelleri ile Veri Odaklı KDS

Büyük Dil Modelleri (Large Language Models - LLM) ve Doğal Dil İşleme (NLP), yapılandırılmamış verilerin analizini otomatikleştirerek, KDS ve YBS kapsamında veri odaklı stratejik içgörüler elde edilmesini sağlamaktadır. Transformers mimarisine dayalı modeller, dikkat mekanizması (self-attention) sayesinde uzun bağlamları anlamlandırarak metin tabanlı verileri derinlemesine analiz edebilmekte ve organizasyonların büyük ölçekli veri yönetimini optimize etmektedir (Tang vd., 2018). BERT (Bidirectional Encoder Representations from Transformers), çift yönlü bağlam analizi yaparak kelimelerin anlamını cümle içindeki konumlarına göre belirlemekte ve semantik analiz süreçlerinde yüksek doğruluk sağlamaktadır (Deepa ve Tamilarasi, 2021). GPT (Generative Pre-trained Transformer) ve T5 (Text-to-Text Transfer Transformer) gibi modeller ise metin üretimi, özetleme ve soru-cevap sistemlerinde, dilin bağlamsal yapısını koruyarak bilgi çıkarım süreçlerini güçlendirmektedir. LLaMA (Large Language Model Meta AI) gibi daha optimize edilmiş modeller, LLM'nin kurumsal uygulamalara entegrasyonunu kolaylaştırarak, hesaplama maliyetlerini düşürmekte ve performansı artırmaktadır (Hadi vd., 2023). YBS bağlamında, NLP tabanlı metin madenciliği algoritmaları, yapılandırılmamış metinleri işleyerek kurumsal karar alma süreçlerini desteklemektedir. Duygu analizi (sentiment

analysis), müşteri geri bildirimlerinden ve sosyal medya verilerinden eğilimleri belirlemek için kullanılmakta (Sinap, 2024b), semantik analiz yöntemleri ise kurumsal belgeler ve sözleşmeler üzerinde derinlemesine incelemeler yaparak hukuki ve finansal riskleri minimize etmektedir. Ayrıca, bilgi çıkarımı (named entity recognition - NER) teknikleri, belgeler içindeki kritik varlıkları (şirket isimleri, tarih, finansal göstergeler) tanımlayarak veri tabanlarına yapılandırılmış bilgiler eklemektedir (Ehrmann vd., 2023). Gerçek zamanlı NLP uygulamalarının gelişmesiyle birlikte, LLM yöneticilerin karar alma süreçlerini hızlandırarak, veri tabanlı analizlerde güvenilirliği artırmaktadır. Kurumsal bilgi yönetimi ve otomatik raporlama sistemleriyle entegre edildiğinde, YBS içinde büyük ölçekli veri işleme yetenekleri artırılmakta ve organizasyonların rekabet avantajı elde etmesine katkı sağlanmaktadır.

### **6.7. Tahmine Dayalı Analitik ve Senaryo Simülasyonları ile Stratejik Planlama**

Tahmine dayalı analitik ve senaryo simülasyonları, belirsizliklerin modellenmesini sağlayarak işletmelerin stratejik planlama, kaynak tahsisi ve risk yönetimi süreçlerini optimize etmesine yardımcı olmaktadır. Zaman serisi analizi, dinamik süreçlerin incelenmesi için otoregresif hareketli ortalama (Autoregressive Moving Average - ARMA), otoregresif entegre hareketli ortalama (Autoregressive Integrated Moving Average - ARIMA) ve mevsimsel ARIMA (Seasonal ARIMA - SARIMA) gibi modeller kullanılarak geleceğe yönelik tahminler üretilmektedir. Daha karmaşık ve doğrusal olmayan desenlerin yakalanması için DL tabanlı yöntemler, özellikle uzun kısa süreli bellek (Long Short-Term Memory - LSTM) ve kapılı tekrarlayan birimler (Gated Recurrent Units - GRU) gibi ağ yapıları, sekans verilerini işleyerek uzun vadeli bağımlılıkları öğrenme kapasitesine sahiptir (Mienye vd., 2024). Bu modeller, YBS kapsamında veri akışlarını analiz ederek işletmelerin pazar eğilimlerini, müşteri taleplerini ve operasyonel süreçlerini daha isabetli bir şekilde yönetmesini sağlamaktadır. MDP, belirsizliğin yüksek olduğu ortamlarda optimal karar politikalarının belirlenmesine olanak tanımakta (He vd., 2020) ve YBS içinde senaryo tabanlı karar alma mekanizmalarının oluşturulmasını desteklemektedir. Dinamik programlama ve pekiştirmeli öğrenme algoritmaları ile entegre edilen MDP, farklı durum geçişleri ve ödül fonksiyonları üzerinden gelecekteki kararların uzun vadeli etkilerini hesaplamaktadır. Monte Carlo simülasyonları ise olasılık dağılımlarına dayalı çoklu senaryo üretimi yaparak risk faktörlerinin ve alternatif karar yollarının analiz edilmesini sağlamaktadır.

## 6.8. Federatif Öğrenme ile Dağıtık ve Güvenli Model Eğitimi

Federatif öğrenme (Federated Learning - FL), merkezi bir veri havuzu oluşturmadan dağıtık veri kaynakları üzerinde model eğitimi gerçekleştiren bir ML paradigmasıdır (He vd., 2020) ve YBS kapsamında veri güvenliği, mahremiyet ve hesaplama verimliliği açısından önemli avantajlar sunmaktadır. Bu yaklaşım, merkezi sunuculara bağımlılığı azaltarak hem veri sahipliği ilkesini korumakta hem de uç cihazlarda işlem yaparak gecikmeleri minimize etmektedir (Abreha vd., 2022). Google tarafından geliştirilen Federated Averaging (FedAvg) algoritması, her istemcide yerel olarak eğitilmiş model ağırlıklarını merkezi bir sunucuda ortalama alarak güncellenmiş bir küresel model oluşturulmasını sağlamaktadır. Bu yöntem, özellikle heterojen veri dağılımına sahip sistemlerde yerel modellerin kişiselleştirilmesine olanak tanırken, aynı zamanda merkezi sunucuya ham veri gönderme gereksinimini ortadan kaldırarak veri mahremiyetini güçlendirmektedir. Daha gelişmiş federatif optimizasyon yaklaşımları arasında FedProx, FedOpt ve diferansiyel gizlilik (Differential Privacy) teknikleri yer almakta olup, bu yöntemler model güncellemelerinin güvenli bir şekilde paylaşılmasını ve dağıtık sistemlerde eğitim süreçlerinin daha etkin yürütülmesini mümkün kılmaktadır. YBS bağlamında, federatif öğrenme, farklı organizasyonların veya birimler arasındaki veri paylaşımı kısıtlarını aşarak iş süreçlerinde kolektif öğrenmeyi teşvik etmektedir. Örneğin, işletmelerin kullanıcı verilerini koruyarak kişiselleştirilmiş öneri sistemleri geliştirmesi veya tedarik zinciri yönetiminde farklı aktörlerin kendi verilerini merkezi sunucuya aktarmadan ortak tahmin modelleri oluşturması gibi senaryolar, FL'nin kurumsal bilgi yönetimi ve karar destek süreçlerine nasıl entegre edilebileceğini göstermektedir. Bunun yanı sıra, blokzincir ve güvenilir yürütme ortamları (TEE) gibi teknolojilerle birleştirildiğinde, FL'nin güvenilirlik ve veri bütünlüğü açısından daha sağlam hale getirilmesi mümkün olmaktadır. Bu çerçevede federatif öğrenme, veri güvenliği ve mahremiyet gereksinimlerini karşılayarak dağıtık bilişim ortamlarında etkin ML modellerinin geliştirilmesini sağlamakta ve YBS ile entegre edildiğinde organizasyonların karar alma süreçlerini merkezi olmayan ancak koordineli bir şekilde optimize etmesine katkıda bulunmaktadır.

## 6.9. Bağlamsal Anlamlandırma ve Önleyici Karar Mekanizmaları

Yeni nesil KDS, veriyi bağlamsal olarak anlamlandırabilen ve önleyici aksiyonlar alabilen akıllı sistemler hâline dönüşecektir. Kural tabanlı KDS'ler, belirli kurallara ve öngörülebilir desenlere dayanarak veri analizi gerçekleştirirken, yeni nesil sistemler çevresel bağlamı anlayarak daha derin ve anlamlı içgörüler üretecektir. Bu dönüşüm, karar alma süreçlerini yalnızca veriye dayalı bir reaktivite düzeyinden çıkarıp, gelecekte oluşabilecek

senaryoları modelleyerek organizasyonları olası fırsat ve tehditlere karşı hazırlıklı hâle getiren öngörülü mekanizmalara dönüştürecektir. Bu bağlamsal anlamlandırma süreci, yalnızca içsel veri kaynaklarını analiz etmekle kalmayıp, dışsal faktörleri ve çevresel değişkenleri de sürece dahil ederek daha bütüncül bir karar alma yaklaşımı sunacaktır. Örneğin, bir işletme için çalışan bir KDS'nin analiz süreci geçmiş satış verilerini ve müşteri eğilimlerini incelemekten çok daha fazlasını kapsayacaktır. Bu sistem, pazar dinamiklerini, ekonomik göstergeleri, demografik değişimleri ve rakiplerin fiyatlandırma stratejilerini sürekli olarak analiz ederek, gelecekte oluşabilecek trendleri tahmin edebilecek kapasiteye sahip olacaktır. Bunun yanı sıra, üretim kapasitesi, tedarik zinciri kısıtları, operasyonel maliyetler ve envanter seviyeleri gibi içsel parametreleri de göz önünde bulundurarak, şirketin kaynaklarını en verimli şekilde yönetmesini sağlayacak içgörüler sunacaktır.


Bağlamsal farkındalığa sahip bir KDS, yalnızca mevcut durumu değerlendirmekle yetinmeyerek, bu çok boyutlu analizlerden elde edilen verileri sentezleyerek karar alıcılara önceden harekete geçmeyi sağlayacak aksiyon önerileri sunacaktır. Belirli bir bölgede artan tüketici talebini erken aşamada tespit eden sistem, üretim kapasitesinin artırılmasını veya belirli bir tedarikçinin önceden sipariş verilerek stok seviyelerinin optimize edilmesini önerebilir. Bu sayede, organizasyonlar ani talep değişimlerine veya piyasa dalgalanmalarına hızlı ve bilinçli bir şekilde tepki verebilir. Benzer şekilde, bir KDS, küresel ekonomik dalgalanmalar veya tedarik zinciri krizleri gibi dışsal tehditleri önceden algılayarak şirketin risk yönetimi stratejilerini güncellemesine yardımcı olabilir. Bağlamsal analiz kapasitesinin artmasıyla birlikte, KDS'ler yalnızca işletme yönetimi veya finans gibi alanlarla sınırlı kalmayıp, savunma stratejilerinden şehir planlamasına, enerji yönetiminden kamu politikalarına kadar geniş bir yelpazede kullanılabilir hale gelecektir. Bir şehir planlama sürecinde, trafik akışı verileri, hava kalitesi ölçümleri, nüfus hareketlilik trendleri ve altyapı kapasiteleri gibi faktörleri analiz eden bir KDS, yeni yolların veya toplu taşıma hatlarının nerede inşa edilmesi gerektiğine dair öngörüler sunabilir. Benzer şekilde, enerji yönetiminde kullanılan bir KDS, enerji talep tahminlerini gerçek zamanlı olarak analiz ederek enerji üretim ve dağıtım süreçlerini optimize edebilir, böylece kaynakların daha verimli kullanılmasını sağlayabilir. Savunma alanında ise KDS'lerin bağlamsal anlamlandırma yetenekleri askeri operasyonları daha öngörülebilir ve stratejik hâle getirebilir. Örneğin, bir askeri KDS, hava durumu tahminlerinden istihbarat raporlarına, lojistik kapasiteden düşman hareketlilik analizlerine kadar geniş bir veri havuzunu analiz ederek komutanlara en uygun harekât planlarını önerebilir. Kamu politikalarında ise sağlık hizmetleri planlamasından afet yönetimine kadar birçok alanda

KDS'lerin bağlamsal analiz yetenekleri karar süreçlerini daha etkin hale getirebilir. Bir pandemi sürecinde, bir KDS hastalık yayılım hızını, sağlık altyapısının kapasitesini ve toplumun hareketlilik verilerini analiz ederek kamu sağlığı otoritelerine en uygun müdahale senaryolarını önerebilir. Bağlamsal analiz ve proaktif karar alma yetenekleriyle donatılmış yeni nesil KDS'ler, organizasyonları sadece reaktif olmaktan çıkarıp, geleceği öngörerek stratejik avantaj elde eden aktörler hâline getirecektir. Gelişen yapay zekâ ve büyük veri analitiği teknolojileri sayesinde, bu sistemler giderek daha sofistike hale gelerek insan karar alma mekanizmalarının vazgeçilmez bir destekleyicisi olacaktır. Bu dönüşüm, organizasyonların belirsizlikleri daha iyi yönetmesine ve dinamik piyasa koşullarına hızla uyum sağlamasına olanak tanıyarak, rekabet avantajı sağlamalarına yardımcı olacaktır.

### **6.10. Güvenlik, Etik ve Düzenleyici Çerçevelerin Yeniden Tanımlanması**

KDS, büyük ölçekli ve karmaşık veri kaynaklarını işleyerek karar alma süreçlerine yön verdiğinden, güvenlik ve etik konular bu sistemlerin tasarım ve uygulanabilirliği açısından kritik bir hale gelmektedir. Artan veri hacmi ve heterojen veri kaynaklarının kullanımı, sistemlerin siber tehditlere karşı daha hassas olmasına neden olmakta ve veri bütünlüğünün korunmasını zorunlu kılmaktadır. Güvenlik risklerini minimize etmek adına, KDS içerisinde veri doğrulama, kimlik doğrulama ve erişim kontrol mekanizmalarının güçlendirilmesi gerekmektedir. Geleneksel güvenlik yöntemleri, merkezi veri yönetimi ve denetim süreçleriyle güvenliği sağlamaya çalışırken, merkezi olmayan güvenlik yaklaşımları, blokzincir tabanlı dağıtık defter teknolojileri, veri güvenliğini artırmada önemli bir alternatif sunmaktadır. Blokzincir teknolojisi, veri manipülasyonunu önleyerek, karar destek süreçlerinde güvenilirlik ve bütünlük sağlamaktadır (Wei vd., 2020). Buna ek olarak, gelişmiş kriptografik yöntemlerin KDS ile bütünleşmesi, veri gizliliği ve güvenliğini sağlamak açısından önemlidir. Homomorfik şifreleme teknikleri, verilerin şifreli halde analiz edilmesine olanak tanıyarak (Alloghani vd., 2019), sıfır bilgi ispatı (zero-knowledge proof) gibi mekanizmalar, verinin içeriğini açığa çıkarmadan doğrulama süreçlerinin yürütülmesini mümkün kılmaktadır (Sun vd., 2021). Bu tür gelişmiş şifreleme tekniklerinin KDS ile entegrasyonu, hassas veriler içeren karar süreçlerinde, veri gizliliğini sağlamaya yönelik önemli bir adımdır. Ancak, bu tür güvenlik çözümlerinin uygulanması, işlem maliyetlerini artırabilmekte ve sistemlerin ölçeklenebilirliğini etkileyebilmektedir. Bu nedenle, güvenlik ile performans arasında dengeli bir yapı oluşturulması gerekmektedir.

KDS'nin yapay zekâ tabanlı modellerle entegre edilmesi, yalnızca teknik güvenlik önlemleriyle sınırlı kalmayıp, etik sorumlulukları da beraberinde getirmektedir. ML ve DL tabanlı modellerin KDS'ye entegrasyonu, algoritmik önyargıların ortaya çıkmasına neden olabilmekte ve karar alma süreçlerinde adalet, hesap verebilirlik ve şeffaflık gibi etik prensiplerin sağlanmasını zorunlu kılmaktadır. Veri setlerindeki sistematik hatalar veya önyargılar, KDS'nin taraflı sonuçlar üretmesine neden olabileceğinden, kullanılan veri kümelerinin dengeli ve temsil edici olması büyük önem taşımaktadır (Pagano vd., 2023). Bu bağlamda, algoritmik önyargının tespiti ve analizi için çeşitli metrikler kullanılmaktadır. Önyargının kaynağını belirlemek ve modellerin tarafsızlığını ölçmek amacıyla adalet (fairness), kesinlik (precision), duyarlılık (recall) ve farklı gruplar arasındaki performans farkları gibi ölçütler değerlendirilmelidir. Burada “gruplar” kavramı, modelin değerlendirdiği farklı demografik, sosyo-ekonomik veya sınıflandırma kategorilerini ifade etmektedir. Örneğin, yaş grupları, cinsiyet, etnik köken veya gelir seviyeleri gibi değişkenler, modelin belirli bir grup lehine veya aleyhine sistematik olarak yanlı davranıp davranmadığını analiz etmek için kullanılabilir. Önyargı tespitine yönelik kullanılan metrikler ve farklı gruplar arasındaki dağılım Şekil 3'te görselleştirilmiştir.



Şekil 3. Algoritmik Önyargı Tespiti için Kullanılan Metrikler

Bunun yanı sıra, modelin çıktılarının yorumlanabilir olması, sistemlerin denetlenebilirliğini ve güvenilirliğini artırmakta, kullanıcıların alınan kararları anlamasını kolaylaştırmaktadır. YBS perspektifinden değerlendirildiğinde, KDS'nin şeffaf, hesap verebilir ve denetlenebilir olması, organizasyonların karar alma süreçlerinde etik yapay zekâ politikalarını benimsemesini zorunlu hale getirmektedir. Bu doğrultuda, etik ilkelerin KDS'nin geliştirilme aşamasında dikkate alınması ve yapay zekâ modellerinin açıklanabilirliğini sağlayan mekanizmaların entegrasyonu gerekmektedir. Etik denetim mekanizmaları, sistemlerin yalnızca teknik doğruluk ve güvenilirlik açısından değil, aynı zamanda etik uygunluk açısından da değerlendirilmesini sağlayarak, KDS'nin sürdürülebilir ve güvenilir bir yapıya kavuşmasını desteklemektedir.

## 7. Sonuç ve Öneriler

Bu çalışma, YZ-KDS'nin YBS ile entegrasyonunu kapsamlı bir şekilde incelemiş ve bu sistemlerin işletmelerin karar alma süreçlerinde nasıl dönüştürücü bir rol oynadığını ortaya koymuştur. YZ-KDS, büyük veri analitiği, ML ve DL gibi ileri teknolojilerle desteklenerek, geleneksel KDS'lerin sınırlarını aşmış ve daha dinamik, öngörücü ve otomatik karar mekanizmaları sunmuştur. Bu sistemler, işletmelerin operasyonel verimliliğini artırırken, stratejik karar alma süreçlerinde de önemli bir rekabet avantajı sağlamaktadır. Ancak, bu dönüşüm süreci sadece teknik bir evrim değil, aynı zamanda organizasyonel, yönetsel ve etik boyutları da içeren kapsamlı bir değişimi gerektirmektedir.

YZ-KDS'nin başarılı bir şekilde uygulanabilmesi için, öncelikle veri kalitesi ve bütünlüğünün sağlanması kritik öneme sahiptir. Veri temizleme, doğrulama ve anlamsal bütünlük süreçleri, sistemlerin güvenilirliğini artırmak için dikkatle yönetilmelidir. Veri setlerindeki eksiklikler, tutarsızlıklar veya yanlış etiketlemeler, modelin eğitimi sırasında yanlış örüntülerin öğrenilmesine yol açarak, tahmin performansını olumsuz yönde etkileyebilir. Bu nedenle, veri işleme süreçlerinde sistematik doğrulama mekanizmalarının uygulanması ve istatistiksel analiz yöntemleriyle verinin güvenilirliğinin sağlanması gerekmektedir. Ayrıca, veri güncelleme süreçlerinin belirli aralıklarla gerçekleştirilmesi ve değişen veri dağılımlarına uyum sağlayabilen dinamik öğrenme mekanizmalarının geliştirilmesi önemlidir.

Model şeffaflığı ve yorumlanabilirliği, özellikle DL tabanlı sistemlerde karşılaşılan önemli bir zorluktur. DL modelleri, karmaşık çok katmanlı sinir ağları ve büyük boyutlu parametre kümeleri ile çalıştığından, elde edilen tahminlerin nasıl üretildiğini anlamak zorlaşmaktadır. Bu durum,



sistemlerin güvenilirliği ve hesap verebilirliği açısından çeşitli riskler yaratmaktadır. Bu teknik zorlukların üstesinden gelmek amacıyla XAI yöntemleri geliştirilmektedir. XAI yaklaşımları, modelin aldığı kararların nedenlerini daha anlaşılır hale getirmeyi amaçlamakta ve belirli bir tahminin hangi faktörler doğrultusunda oluşturulduğunu matematiksel olarak analiz edebilme olanağı sunmaktadır. Bu bağlamda, model şeffaflığını artırmak için çeşitli post-hoc analiz yöntemleri, duyarlılık analizleri ve karar ağaçları gibi teknikler uygulanmalıdır.

Ölçeklenebilirlik ve işlem gücü gereksinimleri, YZ-KDS'nin teknik kısıtları arasında önemli bir yer tutmaktadır. YZ tabanlı sistemlerin etkin çalışabilmesi için büyük miktarda verinin yüksek hızda işlenmesi ve analiz edilmesi gerekmektedir. DL tabanlı modeller yüksek işlem gücüne ihtiyaç duymaktadır. Bu gereksinimleri karşılamak için paralel hesaplama, bulut bilişim ve dağıtık sistemler gibi teknolojiler etkin bir şekilde kullanılmalıdır. Bulut bilişim platformları, esnek kaynak tahsisi ve yüksek işlem kapasitesi sunarak, büyük ölçekli hesaplama gereksinimlerine sahip sistemlerin maliyet etkin bir şekilde çalıştırılmasını sağlamaktadır. Ancak, bulut tabanlı sistemlerin kullanımı, veri güvenliği, gecikme süreleri ve operasyonel maliyetler gibi faktörleri de beraberinde getirmektedir. Bu nedenle, kaynakların etkin bir şekilde kullanılması ve optimize edilmiş algoritmaların geliştirilmesi, KDS'nin sürdürülebilirliğini sağlamak açısından önemli bir strateji olarak öne çıkmaktadır.

Güvenlik ve gizlilik, YZ-KDS'nin uygulanabilirliği açısından kritik bir faktördür. Büyük veri analitiği temelli çalışan bu sistemler, yüksek hacimli ve çeşitli veri kaynaklarından gelen bilgileri işleyerek karar alma süreçlerini desteklemektedir. Ancak, bu süreçte işlenen veriler arasında hassas, gizli veya kişisel bilgiler bulunabileceğinden, veri güvenliği açıkları ve yetkisiz erişim riskleri ciddi tehditler oluşturmaktadır. Bu nedenle, YZ-KDS'nin güvenliğini sağlamak amacıyla kapsamlı bir güvenlik mimarisi oluşturulmalı ve veri koruma stratejileri çok katmanlı bir yaklaşımla ele alınmalıdır. Anonimleştirme teknikleri, güvenli veri paylaşım protokolleri, MFA, veri şifreleme yöntemleri ve erişim izleme sistemleri gibi güvenlik önlemleri, büyük veri ekosistemlerinin korunmasına yönelik önemli bileşenlerdir.

YZ-KDS'nin yapay zekâ tabanlı modellerle entegre edilmesi, yalnızca teknik güvenlik önlemleriyle sınırlı kalmayıp, etik sorumlulukları da beraberinde getirmektedir. ML ve DL tabanlı modellerin KDS'ye entegrasyonu, algoritmik önyargıların ortaya çıkmasına neden olabilmekte ve karar alma süreçlerinde adalet, hesap verebilirlik ve şeffaflık gibi etik prensiplerin sağlanmasını zorunlu kılmaktadır. Veri setlerindeki sistematik hatalar veya

önyargılar, KDS'nin taraflı sonuçlar üretmesine neden olabileceğinden, kullanılan veri kümelerinin dengeli ve temsil edici olması büyük önem taşımaktadır. Bu bağlamda, algoritmik önyargının tespiti ve analizi için çeşitli metrikler kullanılmalı ve modelin çıktılarının yorumlanabilir olması sağlanmalıdır. Ayrıca, etik ve yasal düzenlemelere uyum, kişisel verilerin korunması ve algoritmik önyargıların önlenmesi açısından büyük önem taşımaktadır. Organizasyonlar, YZ-KDS'nin geliştirilmesi ve uygulanması sürecinde etik ilkeleri göz önünde bulundurmalı ve sistemlerin hesap verebilirliğini sağlamak için gerekli denetim mekanizmalarını oluşturmalıdır.

Gelecekte, YZ-KDS'nin daha da gelişmesi ve yaygınlaşması beklenmektedir. Özellikle, kuantum hesaplama, ZTA ve yapay zekâ destekli güvenlik sistemleri gibi yenilikçi teknolojiler, bu sistemlerin güvenliğini ve performansını artıracaktır. Ayrıca, sürekli öğrenen ve adaptif sistemlerin geliştirilmesi, karar destek süreçlerinin daha esnek ve dinamik hale gelmesini sağlayacaktır. Bu bağlamda, işletmelerin YZ-KDS'ye yönelik stratejilerini geliştirirken hem teknik hem de yönetsel faktörleri dikkate almaları ve bu sistemlerin sunduğu fırsatları en üst düzeye çıkarmak için gerekli altyapıyı oluşturmaları önerilmektedir. YZ-KDS'nin başarılı bir şekilde entegre edilmesi, işletmelerin veri odaklı karar alma kapasitelerini artırarak, rekabetçi bir avantaj elde etmelerine önemli bir katkı sağlayacaktır.

## Kaynakça

- Abreha, H. G., Hayajneh, M., & Serhani, M. A. (2022). Federated learning in edge computing: a systematic survey. *Sensors*, 22(2), 450.
- Adadi, A. (2021). A survey on data-efficient algorithms in big data era. *Journal of Big Data*, 8(1), 24.
- Alam, M. A., Nabil, A. R., Mintoo, A. A., & Islam, A. (2024). Real-Time Analytics In Streaming Big Data: Techniques And Applications. *Journal of Science and Engineering Research*, 1(01), 104-122.
- Alawamleh, H. A., ALShibly, M. H. A. A., Tommalieh, A. F. A., Al-Qaryouti, M. Q. H., & Ali, B. J. (2021). The challenges, barriers and advantages of management information system development: Comprehensive review. *Academy of Strategic Management Journal*, 20(5), 1-8.
- Al-Jumaili, A. H. A., Muniyandi, R. C., Hasan, M. K., Paw, J. K. S., & Singh, M. J. (2023). Big data analytics using cloud computing based frameworks for power management systems: Status, constraints, and future recommendations. *Sensors*, 23(6), 2952.
- Alloghani, M., Alani, M. M., Al-Jumeily, D., Baker, T., Mustafina, J., Hussain, A., & Aljaaf, A. J. (2019). A systematic review on the status and progress of homomorphic encryption technologies. *Journal of Information Security and Applications*, 48, 102362.
- Asch, M., Moore, T., Badia, R., Beck, M., Beckman, P., Bidot, T., ... & Zacharov, I. (2018). Big data and extreme-scale computing: Pathways to convergence-toward a shaping strategy for a future software and data ecosystem for scientific inquiry. *The International Journal of High Performance Computing Applications*, 32(4), 435-479.
- Badmus, O., Rajput, S. A., Arogundade, J. B., & Williams, M. (2024). AI-driven business analytics and decision making. *World Journal of Advanced Research and Reviews*, 24(1), 616-633.
- Bagheri, M., Bagheritabar, M., Alizadeh, S., Parizi, M. S. S., Matoufinia, P., & Luo, Y. (2024). Machine-Learning-Powered Information Systems: A Systematic Literature Review for Developing Multi-Objective Healthcare Management. *Applied Sciences*, 15(1), 296.
- Bastani, H., Zhang, D. J., & Zhang, H. (2022). Applied machine learning in operations management. *Innovative Technology at the Interface of Finance and Operations: Volume I*, 189-222.
- Bello, O. A. (2023). Machine learning algorithms for credit risk assessment: an economic and financial analysis. *International Journal of Management*, 10(1), 109-133.
- Berber, A., & Srećković, S. (2024). When something goes wrong: Who is responsible for errors in ML decision-making?. *AI & SOCIETY*, 39(4), 1891-1903.

- Berisha-Shaqiri, A. (2014). Management information system and decision-making. *Academic Journal of Interdisciplinary Studies*, 3(2), 19-23.
- Bertino, E., & Ferrari, E. (2017). Big data security and privacy. In *A comprehensive guide through the Italian database research over the last 25 years* (pp. 425-439). Cham: Springer International Publishing.
- Bettis, R. A. (2017). Organizationally intractable decision problems and the intellectual virtues of heuristics. *Journal of Management*, 43(8), 2620-2637.
- Biswas, T. R., Hossain, M. Z., & Comite, U. (2024). Role of Management Information Systems in Enhancing Decision-Making in Large-Scale Organizations. *Pacific Journal of Business Innovation and Strategy*, 1(1), 5-18.
- Brinch, M. (2018). Understanding the value of big data in supply chain management and its business processes: Towards a conceptual framework. *International Journal of Operations & Production Management*, 38(7), 1589-1614.
- Cerezo, M., Arrasmith, A., Babbush, R., Benjamin, S. C., Endo, S., Fujii, K., ... & Coles, P. J. (2021). Variational quantum algorithms. *Nature Reviews Physics*, 3(9), 625-644.
- Chu, D. T., Bai, L. Y., Huang, J. N., Fang, Z. L., Zhang, P., Kang, W., & Ling, H. F. (2024). Enhanced Safety in Autonomous Driving: Integrating a Latent State Diffusion Model for End-to-End Navigation. *Sensors*, 24(17), 5514.
- Chunarkar-Patil, P., & Bhosale, A. (2018). Big data analytics. *Open Access J Sci*, 2(5), 326-335.
- Dahlbom, P., Siikanen, N., Sajasalo, P., & Jarvenpää, M. (2020). Big data and HR analytics in the digital era. *Baltic Journal of Management*, 15(1), 120-138.
- Das, P., Pervin, T., Bhattacharjee, B., Karim, M. R., Sultana, N., Khan, M. S., ... & Kamruzzaman, F. N. U. (2024). Optimizing real-time dynamic pricing strategies in retail and e-commerce using machine learning models. *The American Journal of Engineering and Technology*, 6(12), 163-177.
- Das, S. R., & Varma, S. (2020). Dynamic goals-based wealth management using reinforcement learning. *Journal Of Investment Management*, 18(2), 1-20.
- Deepa, D., & Tamilarasi, A. (2021). Bidirectional encoder representations from transformers (BERT) language model for sentiment analysis task. *Turkish Journal of Computer and Mathematics Education*, 12(7), 1708-1721.
- Ehrmann, M., Hamdi, A., Pontes, E. L., Romanello, M., & Doucet, A. (2023). Named entity recognition and classification in historical documents: A survey. *ACM Computing Surveys*, 56(2), 1-47.
- Ekundayo, F. (2024). Leveraging AI-Driven Decision Intelligence for Complex Systems Engineering. *Int J Res Publ Rev*, 5(11), 1-10.

- Elhoseny, M., Abdelaziz, A., Salama, A. S., Riad, A. M., Muhammad, K., & Sangaiah, A. K. (2018). A hybrid model of internet of things and cloud computing to manage big data in health services applications. *Future generation computer systems*, 86, 1383-1394.
- Erdoğan, U. (2023). A systematic review on the use of artificial intelligence in e-commerce. *Toplum Ekonomi ve Yönetim Dergisi*, 4(Özel), 184-197.
- Erhard, M., Krenn, M., & Zeilinger, A. (2020). Advances in high-dimensional quantum entanglement. *Nature Reviews Physics*, 2(7), 365-381.
- Eze, B., & Peyton, L. (2015). Systematic literature review on the anonymization of high dimensional streaming datasets for health data sharing. *Procedia Computer Science*, 63, 348-355.
- Ge, X., Yang, F., & Han, Q. L. (2017). Distributed networked control systems: A brief overview. *Information Sciences*, 380, 117-131.
- Gill, N., Hall, P., Montgomery, K., & Schmidt, N. (2020). A responsible machine learning workflow with focus on interpretable models, post-hoc explanation, and discrimination testing. *Information*, 11(3), 137.
- Gong, X., Zhang, T., Chen, C. P., & Liu, Z. (2021). Research review for broad learning system: Algorithms, theory, and applications. *IEEE Transactions on Cybernetics*, 52(9), 8922-8950.
- Goswami, M. (2024). AI-based anomaly detection for real-time cybersecurity. *International Journal of Research and Review Techniques*, 3(1), 45-53.
- Gudivada, V., Apon, A., & Ding, J. (2017). Data quality considerations for big data and machine learning: Going beyond data cleaning and transformations. *International Journal on Advances in Software*, 10(1), 1-20.
- Guidotti, R., Monreale, A., Ruggieri, S., Turini, F., Giannotti, F., & Pedreschi, D. (2018). A survey of methods for explaining black box models. *ACM computing surveys (CSUR)*, 51(5), 1-42.
- Gupta, S., Modgil, S., Bhattacharyya, S., & Bose, I. (2022). Artificial intelligence for decision support systems in the field of operations research: review and future scope of research. *Annals of Operations Research*, 308(1), 215-274.
- Hadi, M. U., Qureshi, R., Shah, A., Irfan, M., Zafar, A., Shaikh, M. B., ... & Mirjalili, S. (2023). Large language models: a comprehensive survey of its applications, challenges, limitations, and future prospects. *Authorea Preprints*, 1, 1-26.
- Hameed, A., Khoshkbarforoushha, A., Ranjan, R., Jayaraman, P. P., Kolodziej, J., Balaji, P., ... & Zomaya, A. (2016). A survey and taxonomy on energy efficient resource allocation techniques for cloud computing systems. *Computing*, 98, 751-774.
- Hang, L., & Kim, D. H. (2019). Design and implementation of an integrated iot blockchain platform for sensing data integrity. *sensors*, 19(10), 2228.

- Hassan, M. U., Rehmani, M. H., & Chen, J. (2019). Differential privacy techniques for cyber physical systems: A survey. *IEEE Communications Surveys & Tutorials*, 22(1), 746-789.
- Hassija, V., Chamola, V., Mahapatra, A., Singal, A., Goel, D., Huang, K., ... & Hussain, A. (2024). Interpreting black-box models: a review on explainable artificial intelligence. *Cognitive Computation*, 16(1), 45-74.
- He, C., Li, S., So, J., Zeng, X., Zhang, M., Wang, H., ... & Avestimehr, S. (2020). Fedml: A research library and benchmark for federated machine learning. *arXiv preprint arXiv:2007.13518*.
- He, Y., Xing, L., Chen, Y., Pedrycz, W., Wang, L., & Wu, G. (2020). A generic Markov decision process model and reinforcement learning method for scheduling agile earth observation satellites. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 52(3), 1463-1474.
- Heidari, A., Navimipour, N. J., & Unal, M. (2022). Applications of ML/DL in the management of smart cities and societies based on new trends in information technologies: A systematic literature review. *Sustainable Cities and Society*, 85, 104089.
- Hrabec, D., Hvattum, L. M., & Hoff, A. (2022). The value of integrated planning for production, inventory, and routing decisions: A systematic review and meta-analysis. *International Journal of Production Economics*, 248, 108468.
- Ivanov, D., & Dolgui, A. (2021). A digital supply chain twin for managing the disruption risks and resilience in the era of Industry 4.0. *Production Planning & Control*, 32(9), 775-788.
- Janiesch, C., Zscheck, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic markets*, 31(3), 685-695.
- Jia, T., Wang, C., Tian, Z., Wang, B., & Tian, F. (2022). Design of digital and intelligent financial decision support system based on artificial intelligence. *Computational intelligence and neuroscience*, 2022(1), 1962937.
- Jouppi, N. P., Young, C., Patil, N., Patterson, D., Agrawal, G., Bajwa, R., ... & Yoon, D. H. (2017, June). In-datacenter performance analysis of a tensor processing unit. In *Proceedings of the 44th annual international symposium on computer architecture* (pp. 1-12).
- Kahn, M. G., Callahan, T. J., Barnard, J., Bauck, A. E., Brown, J., Davidson, B. N., ... & Schilling, L. (2016). A harmonized data quality assessment terminology and framework for the secondary use of electronic health record data. *Egems*, 4(1), 1244.
- Karkouch, A., Mousannif, H., Al Moatassime, H., & Noel, T. (2016). Data quality in internet of things: A state-of-the-art survey. *Journal of Network and Computer Applications*, 73, 57-81.

- Kharfan, M., Chan, V. W. K., & Firdolas Efendigil, T. (2021). A data-driven forecasting approach for newly launched seasonal products by leveraging machine-learning approaches. *Annals of Operations Research*, 303(1), 159-174.
- Kodituwakku, S. R. (2015). Biometric authentication: A review. *International Journal of Trend in Research and Development*, 2(4), 113-123.
- Li, X., Xiong, H., Li, X., Wu, X., Zhang, X., Liu, J., ... & Dou, D. (2022). Interpretable deep learning: Interpretation, interpretability, trustworthiness, and beyond. *Knowledge and Information Systems*, 64(12), 3197-3234.
- Lisboa, P. J., Saralajew, S., Vellido, A., Fernández-Domenech, R., & Villmann, T. (2023). The coming of age of interpretable and explainable machine learning models. *Neurocomputing*, 535, 25-39.
- Liu, X. Y., Zhang, Z., Wang, Z., Lu, H., Wang, X., & Walid, A. (2022). High-performance tensor learning primitives using GPU tensor cores. *IEEE Transactions on Computers*, 72(6), 1733-1746.
- Liu, X., Singh, P. V., & Srinivasan, K. (2016). A structured analysis of unstructured big data by leveraging cloud computing. *Marketing science*, 35(3), 363-388.
- Liu, Y., Fieldsend, J. E., & Min, G. (2017). A framework of fog computing: Architecture, challenges, and optimization. *IEEE Access*, 5, 25445-25454.
- Lu, J., Liu, A., Dong, F., Gu, F., Gama, J., & Zhang, G. (2018). Learning under concept drift: A review. *IEEE transactions on knowledge and data engineering*, 31(12), 2346-2363.
- Mahanan, W., Chaovalitwongse, W. A., & Natwichai, J. (2020). Data anonymization: a novel optimal k-anonymity algorithm for identical generalization hierarchy data in IoT. *Service Oriented Computing and Applications*, 14, 89-100.
- Maharana, K., Mondal, S., & Nemade, B. (2022). A review: Data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, 3(1), 91-99.
- Malak, J. S., Zeraati, H., Nayeri, F. S., Safdari, R., & Shahraki, A. D. (2019). Neonatal intensive care decision support systems using artificial intelligence techniques: a systematic review. *Artificial Intelligence Review*, 52, 2685-2704.
- Matta, P., Arora, M., & Sharma, D. (2021). A comparative survey on data encryption Techniques: Big data perspective. *Materials today: proceedings*, 46, 11035-11039.
- Mienye, I. D., Swart, T. G., & Obaido, G. (2024). Recurrent neural networks: A comprehensive review of architectures, variants, and applications. *Information*, 15(9), 517.

- Minh, D., Wang, H. X., Li, Y. F., & Nguyen, T. N. (2022). Explainable artificial intelligence: a comprehensive review. *Artificial Intelligence Review*, 55, 3503–3568.
- Mohamad, M. S. A., Din, R., & Ahmad, J. I. (2021). Research trends review on RSA scheme of asymmetric cryptography techniques. *Bulletin of Electrical Engineering and Informatics*, 10(1), 487-492.
- Mohammed, A. H. Y., Dziyauddin, R. A., & Latiff, L. A. (2023). Current multi-factor of authentication: Approaches, requirements, attacks and challenges. *International Journal of Advanced Computer Science and Applications*, 14(1), 166-178.
- Morais, C., Yung, K. L., Johnson, K., Moura, R., Beer, M., & Patelli, E. (2022). Identification of human errors and influencing factors: A machine learning approach. *Safety science*, 146, 105528.
- Mumali, F. (2022). Artificial neural network-based decision support systems in manufacturing processes: A systematic literature review. *Computers & Industrial Engineering*, 165, 107964.
- Munappy, A. R., Bosch, J., Olsson, H. H., Arpteg, A., & Brinne, B. (2022). Data management for production quality deep learning models: Challenges and solutions. *Journal of Systems and Software*, 191, 111359.
- Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., & Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal of big data*, 2, 1-21.
- Nguyen, T. T., Nguyen, N. D., & Nahavandi, S. (2020). Deep reinforcement learning for multiagent systems: A review of challenges, solutions, and applications. *IEEE transactions on cybernetics*, 50(9), 3826-3839.
- Ning, H., Li, Y., Shi, F., & Yang, L. T. (2020). Heterogeneous edge computing open platforms and tools for internet of things. *Future Generation Computer Systems*, 106, 67-76.
- Okoli, J., & Watt, J. (2018). Crisis decision-making: the overlap between intuitive and analytical strategies. *Management Decision*, 56(5), 1122-1134.
- Olukoya, O. (2023). Time series-based quantitative risk models: enhancing accuracy in forecasting and risk assessment. *International Journal of Computer Applications Technology and Research*, 12(11), 29-41.
- Omotunde, H., & Ahmed, M. (2023). A comprehensive review of security measures in database systems: Assessing authentication, access control, and beyond. *Mesopotamian Journal of CyberSecurity*, 2023, 115-133.
- Pagano, T. P., Loureiro, R. B., Lisboa, F. V., Peixoto, R. M., Guimarães, G. A., Cruz, G. O., ... & Nascimento, E. G. (2023). Bias and unfairness in machine learning models: a systematic review on datasets, tools, fairness metrics, and identification and mitigation methods. *Big data and cognitive computing*, 7(1), 15.



- Rane, N. L., Paramesha, M., Choudhary, S. P., & Rane, J. (2024). Artificial intelligence, machine learning, and deep learning for advanced business strategies: a review. *Partners Universal International Innovation Journal*, 2(3), 147-171.
- Rasul, I., Akter, T., Akter, S., Eshra, S. A., & Hossain, A. (2025). AI-Driven Business Analytics for Product Development: A Survey of Techniques and Outcomes in the Tech Industry. *Frontline Marketing, Management and Economics Journal*, 5(01), 16-38.
- Razmak, J., & Aouni, B. (2015). Decision support system and multi-criteria decision aid: a state of the art and perspectives. *Journal of Multi-Criteria Decision Analysis*, 22(1-2), 101-117.
- Rimon, S. T. H. (2024). Leveraging Artificial Intelligence in Business Analytics for Informed Strategic Decision-Making: Enhancing Operational Efficiency, Market Insights, and Competitive Advantage. *Journal of Artificial Intelligence General science (JAIGS)*, 6(1), 600-624.
- Safdar, S., Zafar, S., Zafar, N., & Khan, N. F. (2018). Machine learning based decision support systems (DSS) for heart disease diagnosis: a review. *Artificial Intelligence Review*, 50(4), 597-623.
- Salman, T., Zolanvari, M., Erbad, A., Jain, R., & Samaka, M. (2018). Security services using blockchains: A state of the art survey. *IEEE communications surveys & tutorials*, 21(1), 858-880.
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN computer science*, 2(3), 160.
- Sarker, I. H. (2022). AI-based modeling: techniques, applications and research issues towards automation, intelligent and smart systems. *SN computer science*, 3(2), 158.
- Saxena, U. R., & Alam, T. (2023). Provisioning trust-oriented role-based access control for maintaining data integrity in cloud. *International Journal of System Assurance Engineering and Management*, 14(6), 2559-2578.
- Sei, Y., Okumura, H., Takenouchi, T., & Ohsuga, A. (2017). Anonymization of sensitive quasi-identifiers for l-diversity and t-closeness. *IEEE transactions on dependable and secure computing*, 16(4), 580-593.
- Selvarajan, G. P. (2022). Adaptive architectures and real-time decision support systems: integrating streaming analytics for next-generation business intelligence. *IRE Journals*, 5(9), 651-662.
- Sharma, M., Tomar, A., & Hazra, A. (2024). Edge computing for industry 5.0: Fundamental, applications and research challenges. *IEEE Internet of Things Journal*, 11(11), 19070-19093.
- Shollo, A., & Galliers, R. D. (2016). Towards an understanding of the role of business intelligence systems in organisational knowing. *Information Systems Journal*, 26(4), 339-367.

- Siddiqa, A., Karim, A., & Gani, A. (2017). Big data storage technologies: a survey. *Frontiers of Information Technology & Electronic Engineering*, 18, 1040-1070.
- Simuni, G., Sinha, M., Madhuranthakam, R. S., & Vadlakonda, G. (2024). Edge Computing in IoT: Enhancing Real-Time Data Processing and Decision Making in Cyber-Physical Systems. *International Journal of Unique and New Updates*, ISSN: 3079-4722, 6(2), 75-84.
- Sinap, V. (2024a). A comparative study of loan approval prediction using machine learning methods. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 12(2), 644-663.
- Sinap, V. (2024b). Classification of customer sentiments based on online reviews: comparative analysis of machine learning and deep learning algorithms. *Kabramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 27(3), 779-799.
- Singh, A., Mittal, M., & Kapoor, N. (2018). Data processing framework using apache and spark technologies in big data. In *Big Data Processing Using Spark in Cloud* (pp. 107-122). Singapore: Springer Singapore.
- Singh, S. P., Nayyar, A., Kumar, R., & Sharma, A. (2019). Fog computing: from architecture to edge computing and big data processing. *The Journal of Supercomputing*, 75, 2070-2105.
- Soufi, M. D., Samad-Soltani, T., Vahdati, S. S., & Rezaei-Hachesu, P. (2018). Decision support system for triage management: A hybrid approach using rule-based reasoning and fuzzy logic. *International journal of medical informatics*, 114, 35-44.
- Suguna, S., Dhanakoti, V., & Manjupriya, R. (2016). A study on symmetric and asymmetric key encryption algorithms. *Int Res J Eng Technol (IRJET)*, 3(4), 27-31.
- Sun, P. J. (2019). Privacy protection and data security in cloud computing: a survey, challenges, and solutions. *Ieee Access*, 7, 147420-147452.
- Sun, X., Yu, F. R., Zhang, P., Sun, Z., Xie, W., & Peng, X. (2021). A survey on zero-knowledge proof in blockchain. *IEEE network*, 35(4), 198-205.
- Taherdoost, H. (2023). Deep learning and neural networks: Decision-making implications. *Symmetry*, 15(9), 1723.
- Tang, G., Müller, M., Rios, A., & Sennrich, R. (2018). Why self-attention? A targeted evaluation of neural machine translation architectures. *arXiv preprint arXiv:1808.08946*.
- Tantalaki, N., Souravlas, S., & Roumeliotis, M. (2020). A review on big data real-time stream processing and its scheduling techniques. *International Journal of Parallel, Emergent and Distributed Systems*, 35(5), 571-601.
- Tien, J. M. (2017). Internet of things, real-time decision making, and artificial intelligence. *Annals of Data Science*, 4, 149-178.

- Tikkinen-Piri, C., Rohunen, A., & Markkula, J. (2018). EU General Data Protection Regulation: Changes and implications for personal data collecting companies. *Computer Law & Security Review*, 34(1), 134-153.
- Tuli, F. A., Varghese, A., & Ande, J. R. P. K. (2018). Data-driven decision making: A framework for integrating workforce analytics and predictive HR metrics in digitalized environments. *Global Disclosure of Economics and Business*, 7(2), 109-122.
- Usama, M., Qadir, J., Raza, A., Arif, H., Yau, K. L. A., Elkhatib, Y., ... & Al-Fuqaha, A. (2019). Unsupervised machine learning for networking: Techniques, applications and research challenges. *IEEE access*, 7, 65579-65615.
- Van Rijmenam, M., Erekhinskaya, T., Schweitzer, J., & Williams, M. A. (2019). Avoid being the Turkey: How big data analytics changes the game of strategy in times of ambiguity and uncertainty. *Long Range Planning*, 52(5), 101841.
- Vassakis, K., Petrakis, E., Kopanakis, I. (2018). Big Data Analytics: Applications, Prospects and Challenges. In: Skourletopoulos, G., Mastorakis, G., Mavromoustakis, C., Dobre, C., Pallis, E. (eds) Mobile Big Data. Lecture Notes on Data Engineering and Communications Technologies, vol 10. Springer, Cham.
- Villano, F., Mauro, G. M., & Pedace, A. (2024). A review on Machine/Deep learning techniques Applied to Building Energy Simulation, optimization and management. *Thermo*, 4(1), 100-139.
- Wang, P., Li, Y., & Reddy, C. K. (2019). Machine learning for survival analysis: A survey. *ACM Computing Surveys (CSUR)*, 51(6), 1-36.
- Wang, T., Zheng, Z., Rehmani, M. H., Yao, S., & Huo, Z. (2018). Privacy preservation in big data from the communication perspective—A survey. *IEEE Communications Surveys & Tutorials*, 21(1), 753-778.
- Wei, P., Wang, D., Zhao, Y., Tyagi, S. K. S., & Kumar, N. (2020). Blockchain data-based cloud data integrity protection mechanism. *Future Generation Computer Systems*, 102, 902-911.
- Yang, C., Huang, Q., Li, Z., Liu, K., & Hu, F. (2017). Big Data and cloud computing: innovation opportunities and challenges. *International Journal of Digital Earth*, 10(1), 13-53.
- Yarkoni, S., Raponi, E., Bäck, T., & Schmitt, S. (2022). Quantum annealing for industry applications: Introduction and review. *Reports on Progress in Physics*, 85(10), 104001.
- Yu, L., Liu, L., & Peace, K. E. (2020). Regression multiple imputation for missing data analysis. *Statistical methods in medical research*, 29(9), 2647-2664.

- Zhang, H., Chen, G., Ooi, B. C., Tan, K. L., & Zhang, M. (2015). In-memory big data management and processing: A survey. *IEEE Transactions on Knowledge and Data Engineering*, 27(7), 1920-1948.
- Zhang, H., Zhang, M., Liu, F., & Shen, M. (2024). Review of the fractional Black-Scholes equations and their solution techniques. *Fractal and Fractional*, 8(2), 101.
- Zhang, J., Zhong, S., Wang, T., Chao, H. C., & Wang, J. (2020). Blockchain-based systems and applications: a survey. *Journal of Internet Technology*, 21(1), 1-14.
- Zhu, J., Ge, Z., Song, Z., & Gao, F. (2018). Review and big data perspectives on robust data mining approaches for industrial process modeling with outliers and missing data. *Annual Reviews in Control*, 46, 107-133.
- Zuech, R., Khoshgoftaar, T. M., & Wald, R. (2015). Intrusion detection and big heterogeneous data: a survey. *Journal of Big Data*, 2, 1-41.