THBB AKADEMİ

TEKNİK BÜLTEN

17

BETON TEKNOLOJİSİNDE YAPAY ZEKÂ KULLANIMI

TÜRKİYE HAZIR BETON BİRLİĞİ YAYINIDIR.
Haziran, 2025

BETON TEKNOLOJİSİNDE YAPAY ZEKÂ KULLANIMI

1. Beton Teknolojisinin Önemi ve Mevcut Zorluklar

Beton, küresel ölçekte tahmini yıllık 10 milyar tonu aşan üretimiyle dünyada en çok tüketilen yapı malzemesidir ve bu talebin artan nüfus, devam eden sanayileşme ve hızlı kentleşme ile birlikte önümüzdeki yıllarda da artmaya devam etmesi beklenmektedir. Bu yaygın kullanımına rağmen beton, doğası gereği karmaşık bir malzemedir. Farklı bileşenlerin (çimento, agrega, su, katkı maddeleri vb.) ve bu bileşenlerin karışım içindeki oranlarının, betonun hem taze hem de sertleşmiş hâldeki özelliklerini önemli ölçüde etkilediği bilinmektedir. Bu nedenle, istenen performansı sağlayacak beton özelliklerinin elde edilmesi ve doğrulanması uzmanlık gerektiren bir süreçtir.

Geleneksel beton tasarım ve değerlendirme yaklaşımları, sıklıkla deneysel deneme-yanılma süreçlerine dayanır. Bu yöntemler, özellikle yeni nesil betonlar veya alternatif malzeme kullanımları söz konusu olduğunda, optimum çözüme ulaşmak için çok sayıda laboratuvar testi gerektirebilir. Bu durum, proje sürelerini uzatmakta, maliyetleri artırmakta ve malzeme değişkenliklerini her zaman tam olarak yansıtamamaktadır. Ayrıca, inşaat sektörü, dijitalleşme ve yeni teknolojilerin benimsenmesi konusunda diğer birçok sektöre kıyasla daha yavaş bir ilerleme kaydetmektedir. Bu durum, verimlilik kısıtlamaları, iş gücü eksikliği ve bilgiye dayalı karar verme süreçlerindeki zorluklar gibi genel sorunları da beraberinde getirmektedir.

1.1. Yapay Zekâ (YZ) ve Makine Öğreniminin (MÖ) Genel Tanıtımı

Yapay zekâ (YZ), makinelerin öğrenme, akıl yürütme, problem çözme, algılama ve dil anlama gibi tipik olarak insan zekâsı gerektiren görevleri yerine getirmesini sağlayan geniş bir alandır. Makine öğrenimi (MÖ) ise, YZ'nin önemli bir alt kümesi olarak, bilgisayar sistemlerinin açıkça programlanmadan, verilerden öğrenerek performanslarını zamanla iyileştirmelerini sağlayan algoritmalar ve istatistiksel modellerle ilgilenir. MÖ algoritmaları, büyük miktarda geçmiş veriyi analiz ederek örüntüleri tanır ve bu örüntülere dayanarak tahminler ve kararlar üretir **[1].** YZ, betonun davranışını daha iyi modellemek, özelliklerini daha doğru tahmin etmek ve karışım tasarımlarını optimize etmek için son derece uygun bir araçtır. Dolayısıyla, YZ/MÖ'nün beton teknolojisindeki artan popülaritesi ve uygulama alanı bulması, malzemenin doğasındaki zorluklara ve geleneksel yöntemlerin sınırlamalarına doğrudan bir yanıt olarak değerlendirilebilir.

İnşaat sektörünün dijitalleşme konusundaki genel yavaşlığı, YZ/MÖ gibi veri yoğun teknolojilerin beton alanındaki potansiyelini tam olarak gerçekleştirmesinin önünde bir engel teşkil etmektedir. YZ/MÖ uygulamaları, başarılı bir şekilde hayata geçirilebilmek için büyük, kaliteli ve iyi yapılandırılmış

veri setlerine, uygun dijital altyapıya ve veri odaklı bir çalışma kültürüne ihtiyaç duyar. Sektördeki dijitalleşme eksikliği ve verilerin genellikle dağınık bir şekilde tutulması, bu gereksinimlerin karşılanmasını zorlaştırarak YZ/MÖ'nün yaygınlaşmasını yavaşlatmaktadır. Buna rağmen, YZ/MÖ'nün sunduğu kanıtlanmış faydalar (örneğin, maliyet ve zaman tasarrufu, kalite artışı, daha iyi ve hızlı karar verme, kaynak optimizasyonu), sektörü dijitalleşmeye ve dolayısıyla YZ/MÖ'yü benimsemeye teşvik edici bir güç olabilir [1]. Bu teknolojilerin beton teknolojisindeki başarılı uygulamaları, inşaat sektörünün daha geniş çaplı dijital dönüşümü için bir katalizör görevi görebilir; ancak bu, sektörün mevcut kültürel, yapısal ve teknolojik engelleri aşma konusundaki istekliliğine ve çabasına bağlı olacaktır.

2. Beton Teknolojisinde Yapay Zekâ ve Makine Öğreniminin Temel Kavramları

Beton teknolojisinde yapay zekâ ve makine öğrenimi uygulamalarının anlaşılması, bu alandaki temel kavramların, kullanılan yöntemlerin ve süreçlerin bilinmesini gerektirir. Bu bölümde, yaygın YZ/MÖ algoritmaları, veri yönetiminin önemi ve model performansını değerlendirmede kullanılan metrikler ele alınacaktır.

2.1. Temel YZ/MÖ Algoritmaları ve Yaklaşımları

Beton teknolojisinde karşılaşılan problemlerin çözümünde çeşitli YZ/MÖ algoritmaları kullanılmaktadır. Bu algoritmalar, öğrenme biçimlerine göre temel olarak üç ana kategoriye ayrılabilir: 1) denetimli öğrenme, 2) denetimsiz öğrenme ve 3) pekiştirmeli öğrenme. Derin öğrenme ise bu kategoriler altında yer alabilen, özellikle karmaşık problemler için güçlü bir yaklaşım sunan bir alt alandır.

- **Denetimli Öğrenme:** Bu yaklaşımda, algoritma etiketli verilerle eğitilir; yani her bir girdi verisi için karşılık gelen doğru bir çıktı (etiket) bulunur [2]. Model, girdi ve çıktı arasındaki ilişkiyi öğrenerek yeni girdiler için doğru çıktıları tahmin etmeye çalışır. Beton teknolojisinde denetimli öğrenme, genellikle iki tür problem için kullanılır:
    - **Regresyon:** Çıktı değişkeninin sürekli bir sayısal değer olduğu durumlardır. Örneğin, beton

karışım bileşenlerine (girdi) karşılık basınç dayanımının (çıktı) tahmin edilmesi bir regresyon problemidir. Yaygın regresyon algoritmaları arasında Lineer Regresyon, Destek Vektör Regresyonu (SVR), Karar Ağaçları Regresyonu, Rastgele Orman (Random Forest - RF) Regresyonu ve Yapay Sinir Ağları (Artificial Neural Networks - ANN) tabanlı regresyon modelleri bulunur [3].

- **Sınıflandırma:** Çıktı değişkeninin önceden tanımlanmış kategorilerden (sınıflardan) biri olduğu durumlardır. Örneğin, bir beton görüntüsünün "çatlaklı" veya "çatlaksız" olarak sınıflandırılması bir sınıflandırma problemidir [1]. Yaygın sınıflandırma algoritmaları arasında Lojistik Regresyon, Destek Vektör Makineleri (SVM), Karar Ağaçları, Rastgele Orman ve Naive Bayes sınıflandırıcıları yer alır.

- **Denetimsiz Öğrenme:** Bu yaklaşımda, algoritma etiketsiz verilerle çalışır ve verilerdeki gizli örüntüleri, yapıları veya ilişkileri kendi başına keşfetmeye çalışır [2]. Beton teknolojisinde, malzeme özelliklerine göre beton türlerini gruplamak veya veri setindeki boyut sayısını azaltarak enformasyonu korumak (boyut azaltma) gibi görevlerde kullanılabilir.
- **Pekiştirmeli Öğrenme:** Bu yaklaşımda, bir "ajan" belirli bir ortamda deneme-yanılma yoluyla en iyi eylemleri öğrenir **[2].** Ajan, yaptığı her eylem için bir ödül veya ceza alır ve amacını (genellikle toplam ödülü maksimize etmek) gerçekleştirecek bir strateji geliştirmeye çalışır. Beton teknolojisinde henüz yaygın bir uygulama alanı bulamamış olsa da robotik kontrollü beton dökümü veya yapısal denetim rotalarının optimizasyonu gibi alanlarda potansiyel sunabilir.
- **Derin Öğrenme:** Derin öğrenme, çok sayıda katmana (derin mimarilere) sahip yapay sinir ağlarını kullanan bir makine öğrenimi alt alanıdır [4]. Bu katmanlar, verilerden hiyerarşik bir şekilde özellikler öğrenir; alt katmanlar basit özellikleri (örneğin, bir görüntüdeki kenarlar), üst katmanlar ise daha karmaşık ve soyut özellikleri (örneğin, bir görüntüdeki nesneler) öğrenir. Özellikle Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN'ler) görüntü tanıma, nesne tespiti ve görüntü sınıflandırma gibi görevlerde son derece başarılıdır ve beton çatlak tespiti gibi uygulamalarda yaygın olarak kullanılır [5]. Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN'ler) ve Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) ağları ise zaman serisi verilerinin (örneğin, bir yapının zaman içindeki davranışı) analizi için uygundur.

Derin öğrenmenin yükselişi, özellikle görüntü tabanlı analizlerde (örneğin, beton yüzeylerindeki çatlakların tespiti ve sınıflandırılması) devrim niteliğinde gelişmelere yol açmıştır. CNN'ler gibi derin öğrenme modelleri, görüntü verilerinden karmaşık özellikleri otomatik olarak öğrenme yetenekleri sayesinde, bu tür görevlerde geleneksel görüntü işleme tekniklerine kıyasla genellikle çok daha yüksek doğruluk ve etkinlik göstermiştir [1], ancak bu güçlü modellerin içsel işleyiş mekanizmaları genellikle oldukça karmaşıktır ve kararlarını veya tahminlerini hangi faktörlere dayanarak verdikleri kolayca anlaşılamaz. Bu durum, "kara kutu" (black box) problemi olarak bilinir [6]. Sağlık, finans gibi kritik alanlarda olduğu gibi, yapıların güvenliği ve dayanıklılığının hayati önem taşıdığı inşaat ve beton teknolojisi sektöründe de model kararlarının şeffaflığı, anlaşılırlığı ve güvenilirliği esastır. Bir modelin neden belirli bir basınç dayanımı değeri tahmin ettiği veya bir bölgeyi neden "çatlaklı" olarak işaretlediği anlaşılamazsa, bu modelin pratik uygulamalarda kabul görmesi ve mühendisler tarafından güvenle kullanılması zorlaşır. Bu durum, model tahminlerine olan güveni artırmak, potansiyel hataları ayıklamak ve model davranışını daha iyi anlamak için Açıklanabilir Yapay Zekâ (Explainable Artificial Intelligence - XAI) tekniklerinin geliştirilmesini ve uygulanmasını zorunlu kılmıştır. SHAP (SHapley Additive exPlanations) değerleri ve LIME (Local Interpretable Model-agnostic Explanations) gibi XAI yöntemleri, modelin belirli bir tahmin için hangi girdi özelliklerine ne kadar ağırlık verdiğini göstererek karar verme sürecine ışık tutmaya çalışır [3]. Dolayısıyla, derin

öğrenmenin beton teknolojisindeki artan başarısı, beraberinde bu güçlü araçları daha güvenilir, şeffaf ve kabul edilebilir kılmak için XAI araştırmalarına ve uygulamalarına yönelik güçlü bir itici güç oluşturmuştur.

2.2. Veri Toplama, Ön İşleme ve Özellik Mühendisliğinin Önemi

YZ/MÖ modellerinin performansı, büyük ölçüde kullanılan verinin hacmine, kalitesine ve uygunluğuna bağlıdır. Beton teknolojisi alanında, geçmiş laboratuvar deneylerinden, saha uygulamalarından, sensör verilerinden ve endüstriyel süreçlerden elde edilen büyük miktardaki tarihsel verinin, YZ/MÖ teknikleri kullanılarak maksimum fayda sağlayacak şekilde değerlendirilmesi büyük bir potansiyel taşımaktadır [1].

Makine öğreniminde veri analizi süreci genellikle birkaç temel adımdan oluşur [1,3]:

1. **Veri Toplama:** İlgili verilerin çeşitli kaynaklardan toplanması ve analiz platformuna aktarılması.
2. **Veri Ön İşleme:** Bu aşama, model performansını doğrudan etkileyen kritik adımları içerir:
    - **Veri Temizleme:** Eksik değerlerin (missing values) doldurulması veya çıkarılması, gürültülü verilerin düzeltilmesi, tutarsızlıkların giderilmesi ve yinelenen kayıtların (duplicate entries) kaldırılması.
    - **Aykırı Değerlerin Ele Alınması:** Veri setindeki genel dağılımdan önemli ölçüde sapan aykırı değerlerin tespit edilmesi ve uygun şekilde yönetilmesi (çıkarılması veya dönüştürülmesi). Interquartile Range (IQR) yöntemi, bu tür aykırı değerleri belirlemek için yaygın olarak kullanılır.
    - **Veri Dönüşümü ve Ölçekleme:** Farklı ölçeklerdeki sayısal özelliklerin, belirli bir aralığa (örneğin, 0-1 normalizasyonu) veya standart bir dağılıma (örneğin, Z-skoru standardizasyonu) getirilmesi. Bu, bazı algoritmaların (özellikle mesafe tabanlı olanlar veya gradyan inişi kullananlar) daha iyi performans göstermesine yardımcı olur.
3. **Özellik Mühendisliği:** Ham verilerden, modelin öğrenme yeteneğini ve tahmin doğruluğunu artıracak yeni, anlamlı özelliklerin türetilmesi sürecidir. Beton teknolojisinde, örneğin, su miktarı ve çimento miktarından "su/çimento oranı" gibi daha bilgilendirici bir özellik türetmek, model performansını önemli ölçüde iyileştirebilir. Özellik seçimi (feature selection) de bu aşamanın bir parçası olup, en ilgili özelliklerin belirlenerek model karmaşıklığının azaltılmasına ve aşırı uymanın (overfitting) önlenmesine yardımcı olur.
4. **Veri Bölme:** Veri setinin genellikle eğitim (training), doğrulama (validation) ve test (testing) olmak üzere üç alt kümeye ayrılması. Model, eğitim seti üzerinde eğitilir, doğrulama seti üzerinde hiper parametre ayarları yapılır ve performansı ayarlanır, son olarak test seti üzerinde modelin genelleme yeteneği ve nihai performansı değerlendirilir.

MÖ algoritmaları temelde "çöp girerse çöp çıkar" (garbage in, garbage out) prensibiyle çalışır. Eğer eğitim için kullanılan veri kümesinde önemli miktarda gürültü, tutarsızlık, eksiklik veya hata bulunuyorsa, model bu kusurlu verilerden yanlış örüntüler öğrenecek ve dolayısıyla yeni veriler üzerinde düşük performans gösterecektir. Bu nedenle, beton teknolojisinde YZ/MÖ uygulamalarının başarısı, sadece gelişmiş ve uygun algoritmalar seçmekle değil, aynı zamanda kullanılacak verinin kalitesini en üst düzeye çıkarmak için kapsamlı, dikkatli ve probleme özgü bir ön işleme süreci uygulamakla da yakından ilişkilidir. Bu adım, genellikle projenin zaman alıcı bir kısmı olmasına rağmen, güvenilir, sağlam ve pratikte kullanılabilir modeller oluşturmanın temel taşıdır.

2.3. Model Değerlendirme Metrikleri

Geliştirilen YZ/MÖ modellerinin performansını objektif bir şekilde değerlendirmek için çeşitli metrikler kullanılır. Bu metrikler, modelin türüne göre farklılık gösterir [3]. Regresyon modelleri için metrikler:

- **Belirlilik Katsayısı (Coefficient of Determination - R^2):** Modelin bağımlı değişkendeki varyansın ne kadarını açıklayabildiğini gösterir. 0 ile 1 arasında bir değer alır; 1'e yakın olması modelin veriye iyi uyduğunu gösterir.
- **Ortalama Mutlak Hata (Mean Absolute Error - MAE):** Tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasıdır. Hatanın büyüklüğünü gösterir ve yorumlanması kolaydır.
- **Ortalama Karesel Hata (Mean Squared Error - MSE):** Tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasıdır. Büyük hatalara daha fazla ağırlık verir.
- **Kök Ortalama Karesel Hata (Root Mean Squared Error - RMSE):** MSE'nin kareköküdür ve MAE gibi hata büyüklüğünü orijinal birimde gösterir, ancak büyük hatalara daha duyarlıdır.

Bu metrikler, geliştirilen YZ/MÖ modellerinin güçlü ve zayıf yönlerini anlamak, farklı modelleri karşılaştırmak ve modelin pratik uygulamalar için yeterince iyi olup olmadığına karar vermek için hayati öneme sahiptir.

3. Beton Teknolojisinde YZ/MÖ Uygulama Alanları

Yapay zekâ ve makine öğrenimi, beton teknolojisinin hemen her aşamasında devrim yaratma potansiyeline sahip çok yönlü araçlar olarak ortaya çıkmaktadır. Karışım tasarımının optimizasyonundan yapıların ömür boyu performansının izlenmesine kadar geniş bir yelpazede uygulamalar geliştirilmekte ve kullanılmaktadır. Bu bölümde, YZ/MÖ'nün beton teknolojisindeki temel uygulama alanları detaylı bir şekilde incelenecektir.

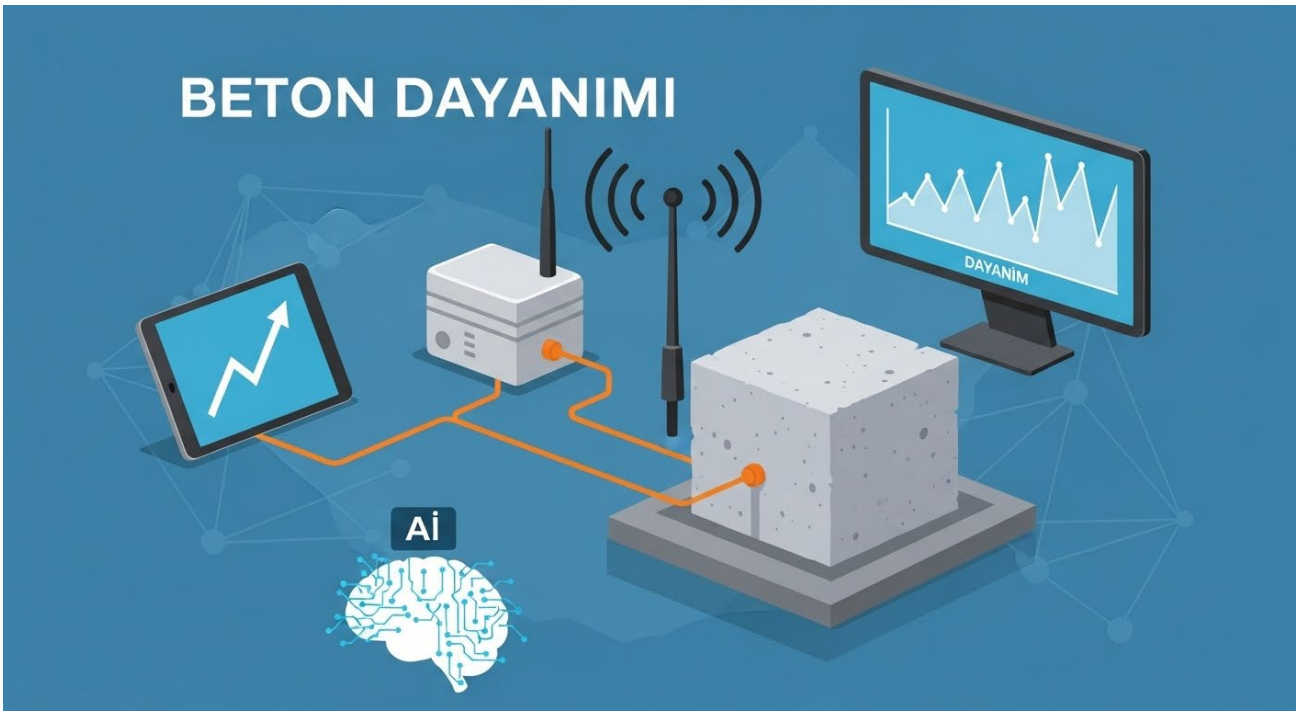

3.1. Beton Karışım Tasarımı ve Optimizasyonu

Beton karışım tasarımı, istenen taze ve sertleşmiş özelliklere (örneğin, işlenebilirlik, dayanım, dayanıklılık) sahip betonu en ekonomik ve sürdürülebilir şekilde üretmek için bileşenlerin (çimento, su, agregalar, kimyasal ve mineral katkılar) uygun oranlarda seçilmesi sürecidir. Geleneksel yöntemler genellikle zaman alıcı deneme-yanılma testlerine dayanırken, YZ/MÖ bu süreci önemli ölçüde hızlandırabilir ve optimize edebilir.

- **Basınç Dayanımı ve Diğer Mekanik Özelliklerin Tahmini:** Betonun en kritik mekanik özelliklerinden biri olan basınç dayanımı, yapısal tasarımın temel bir parametresidir. YZ/MÖ modelleri, betonun karışım bileşenleri (çimento türü ve miktarı, su/bağlayıcı oranı, agrega türü ve granülometrisi, mineral ve kimyasal katkıların türü ve miktarı vb.) ve kür yaşı gibi temel girdilere dayanarak basınç dayanımını yüksek bir doğrulukla tahmin etmek için yaygın bir şekilde kullanılmaktadır [1]. Bu yetenek, yeni karışım tasarımlarının geliştirilmesi veya mevcut tasarımların doğrulanması için gereken zaman alıcı ve maliyetli laboratuvar testlerinin sayısını önemli ölçüde azaltır. Kullanılan YZ/MÖ modelleri arasında Yapay Sinir Ağları (ANN), Destek Vektör Makineleri/Regresyonu (SVM/SVR), Rastgele Orman (RF), Gradyan Artırma Makineleri (Gradient Boosting Machines - GBM, örneğin XGBoost, LightGBM, CatBoost), Karar Ağaçları ve Derin Sinir Ağları (DNN) gibi çeşitli algoritmalar bulunmaktadır [3].
- **Ultra Yüksek Performanslı Beton (UYPB) ve Yüksek Performanslı Beton (YPB) Geliştirilmesi:** UYPB ve YPB, geleneksel betona kıyasla üstün mekanik özellikler (çok yüksek basınç dayanımı, yüksek süneklik) ve dayanıklılık sergileyen gelişmiş çimento bazlı kompozitlerdir, ancak bu betonların karışım tasarımı, çok sayıda bileşenin (özel çimentolar, ince reaktif tozlar, süperakışkanlaştırıcılar, lifler vb.) karmaşık ve birbirleriyle etkileşimli roller oynaması nedeniyle oldukça zordur. YZ/MÖ, bu karmaşık ilişkileri modelleyerek ve çok sayıda potansiyel karışım kombinasyonunu sanal ortamda değerlendirerek optimum karışım oranlarının bulunmasına ve yeni nesil UYPB/YPB formülasyonlarının geliştirilmesine önemli katkılar sağlamaktadır.
- **Geri Dönüştürülmüş ve Alternatif Malzemelerin Kullanımı:** Sürdürülebilirlik ve döngüsel ekonomi hedefleri doğrultusunda, beton üretiminde doğal kaynakların tüketimini azaltmak ve atık miktarını düşürmek amacıyla uçucu kül, yüksek fırın cürufu, silis dumanı gibi endüstriyel yan ürünlerin yanı sıra geri dönüştürülmüş inşaat ve yıkıntı atıklarından elde edilen agregalar (Recycled Concrete Aggregates - RCA), atık cam tozu (Ground Glass Powder - GGP), plastik atıklar ve hatta tarımsal atıklar gibi alternatif malzemelerin kullanımı giderek artmaktadır. Bu malzemelerin özellikleri genellikle geleneksel malzemelere göre daha değişkendir ve beton performansına etkileri karmaşık olabilir. YZ/MÖ, bu alternatif ve geri dönüştürülmüş malzemelerin betonun taze ve sertleşmiş özelliklerine (dayanım, işlenebilirlik, dayanıklılık) etkilerini doğru bir şekilde tahmin ederek ve bu malzemeleri içeren optimum karışım oranlarını belirleyerek bu süreci büyük ölçüde kolaylaştırır ve hızlandırır.

3.2. Betonun Taze, Sertleşen ve Sertleşmiş Hâldeki Özelliklerinin Tahmini

YZ/MÖ teknikleri, betonun sadece nihai sertleşmiş hâldeki mekanik özelliklerini değil, aynı zamanda üretim ve kürlenme sürecindeki davranışlarını da kapsayacak şekilde, yaşam döngüsünün farklı aşamalarındaki özelliklerini modellemek ve tahmin etmek için de kullanılmaktadır [4]. Bu, betonun taze hâldeki özelliklerini (örneğin işlenebilirlik, priz süresi), sertleşme sürecindeki özelliklerini (örneğin hidratasyon ısısı gelişimi, erken yaş dayanım kazanımı) ve nihai sertleşmiş hâldeki özelliklerini (örneğin basınç dayanımı, eğilme dayanımı, elastisite modülü, kuruma rötresi, sünme) içerir.

YZ/MÖ'nün beton özelliklerini taze hâlinden sertleşmiş hâline ve hatta hizmet ömrüne kadar olan süreçte değerlendirme, modelleme ve tahmin etmede kabul edilebilir sonuçlar verdiğini ve bu sayede zaman ve maliyet tasarrufu sağladığını belirtmektedir [1]. Geleneksel yöntemler olan lineer regresyon veya ampirik formüller, betonun heterojen ve karmaşık bileşiminden kaynaklanan doğrusal olmayan ilişkileri yakalamada genellikle yetersiz kalmaktadır. Buna karşılık, Rastgele Orman (RF), XGBoost, Yapay Sinir Ağları (ANN) ve Gen İfade Programlama (Gene Expression Programming - GEP) gibi YZ modelleri, tahmin doğruluğu, ölçeklenebilirlik ve farklı veri setlerine genelleme yapabilme yetenekleri açısından önemli gelişmeler sunmaktadır [7]. Bu modeller, betonun içsel değişkenliğini ve bileşenler arasındaki karmaşık etkileşimleri daha iyi temsil edebilir.

Özellikle betonun erken yaşlardaki dayanım kazanımı, inşaat süreçlerinin hızı ve güvenliği açısından kritik öneme sahiptir (örneğin, kalıp sökme zamanının belirlenmesi, yapıya erken yük uygulanması). Yenilikçi yaklaşımlar**,** gömülü sıcaklık sensörleri aracılığıyla betonun hidratasyon sürecini sürekli olarak izleyerek ve bu verileri özel olarak eğitilmiş YZ modelleriyle (örneğin, Derin Sinir Ağları - DNN) analiz ederek, erken yaş beton basınç dayanımını gerçek zamanlı ve yüksek doğrulukla tahmin edebilmektedir [8]. Bu tür sistemler, şantiyede daha hızlı ve bilinçli kararlar alınmasına olanak tanıyarak inşaat süreçlerini optimize eder.

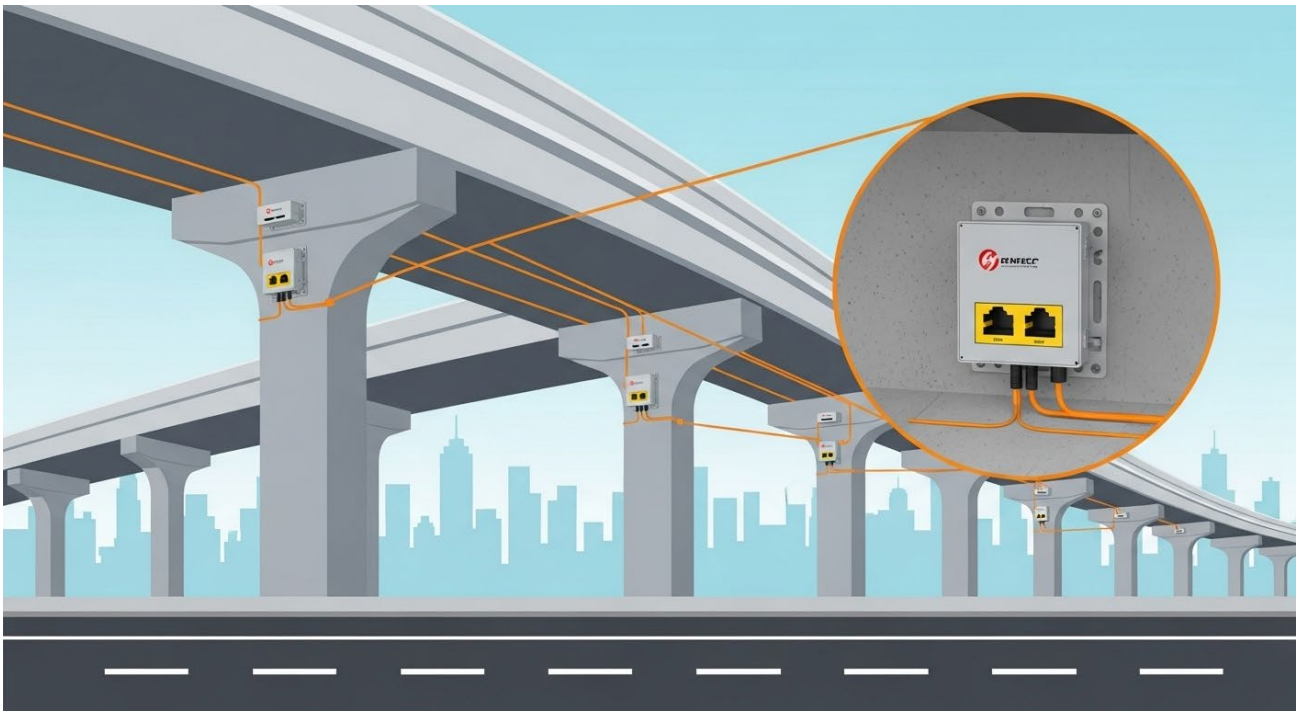

3.3. Yapısal Sağlık İzlemesi (YSİ) ve Hasar Tespiti

Beton yapıların servis ömrü boyunca güvenli ve işlevsel kalmasını sağlamak için yapısal sağlıklarının düzenli olarak izlenmesi ve potansiyel hasarların erken bir aşamada tespit edilmesi hayati önem taşır. YZ/MÖ, bu alanda geleneksel denetim yöntemlerine kıyasla daha hızlı, daha doğru ve daha verimli çözümler sunmaktadır.

- **Çatlak Tespiti ve Sınıflandırılması (Görüntü İşleme, CNN'ler):** Beton yapılarda en sık rastlanan hasar türlerinden biri olan çatlakların tespiti ve değerlendirilmesi, yapısal bütünlüğün korunması için kritik bir adımdır. YZ/MÖ, özellikle derin öğrenme tabanlı CNN'ler, dijital kameralar, dronlar veya robotlar tarafından çekilen görüntülerden veya video akışlarından beton yüzeylerindeki çatlakları otomatik, hızlı ve yüksek bir doğrulukla tespit etmek, sınıflandırmak (örneğin, genişlik, uzunluk, tür) ve hatta ölçmek için yaygın olarak kullanılmaktadır [9].

- **Robotik Denetim Sistemleri:** Büyük ve karmaşık beton yapıların (köprüler, tüneller, binalar) denetimi, özellikle ulaşılması zor veya tehlikeli bölgeler içeriyorsa, geleneksel manuel yöntemlerle zaman alıcı, maliyetli ve riskli olabilir. YZ güdümlü otonom veya yarı otonom robotik sistemler, bu tür denetimleri otomatikleştirmek, hızlandırmak ve daha güvenli hâle getirmek için geliştirilmektedir [4]. Bu sistemler genellikle yüksek çözünürlüklü kameralar, LiDAR (Light Detection and Ranging) tarayıcılar ve diğer sensörlerle donatılmıştır. Topladıkları veriler (görüntüler, nokta bulutları), YZ algoritmaları tarafından işlenerek çatlaklar, dökülmeler, korozyon belirtileri gibi hasarlar tespit edilir ve yapının üç boyutlu bir modeli (dijital ikiz) oluşturulabilir.

  Drexel Üniversitesi araştırmacılarının geliştirdiği bir sistem örnek olarak verilebilir [10]. Bu sistem, önce bilgisayarla görü ve derin öğrenme algoritmalarını kullanarak potansiyel hasarlı bölgeleri belirlemekte, ardından bir robotik kol bu bölgeleri lazer tarayıcı ve LiDAR kamera ile detaylı bir şekilde tarayarak hasarın üç boyutlu bir modelini oluşturmaktadır. Bu sistemin, milimetrenin yüzde birinden daha küçük çatlakları bile hassas bir şekilde tespit edip boyutlandırabildiği rapor edilmiştir. Bu tür robotik sistemler, denetim iş yükünü azaltmanın yanı sıra, zaman içindeki hasar gelişimini izlemek için de değerli veriler sağlar.

- **Tahribatsız Muayene (NDT) Verilerinin Analizi:** Ultrasonik Atım Hızı (UPV), Yer Radarı (GPR), Akustik Emisyon (AE), Vurma-Yankı (Impact-Echo) ve Termal Görüntüleme gibi tahribatsız muayene (NDT) yöntemleri, betonun iç yapısını ve kusurlarını yüzeye zarar vermeden değerlendirmek için kullanılır, ancak bu yöntemlerden elde edilen ham verilerin (örneğin, dalga formları, radar gramlar, termal haritalar) yorumlanması genellikle karmaşıktır ve deneyimli uzmanlık gerektirir. YZ/MÖ algoritmaları, bu büyük ve karmaşık NDT veri setlerini analiz ederek, insan gözünün veya geleneksel analiz yöntemlerinin gözden kaçırabileceği gizli kusurları (iç çatlaklar, boşluklar, delaminasyonlar, donatı korozyonu) tespit etmede, anormallikleri ayırt etmede ve hasarın ciddiyetini değerlendirmede önemli bir rol oynayabilir [9]. YZ, UPV verilerini analiz ederek iç çatlakları veya boşlukları manuel yöntemlere göre daha yüksek bir hassasiyetle tespit edebilir; GPR sinyallerindeki örüntüleri tanımlayarak farklı anomalileri (örneğin, donatı, boşluk, nem) ayırt edebilir ve akustik emisyon sinyallerini sınıflandırarak gelişmekte olan çatlakların yerini ve ciddiyetini belirleyebilir [11]. Bu, NDT süreçlerini daha objektif, hızlı ve güvenilir hâle getirir.

3.4. Beton Dayanıklılığı ve Kalan Kullanım Ömrü Tahmini

Beton yapıların servis ömrü boyunca çeşitli çevresel etkilere (donma-çözülme, karbonatlaşma, klorür ve sülfat saldırısı, alkali-silika reaksiyonu vb.) ve mekanik yüklere maruz kalması, zamanla özelliklerinde bozulmalara ve dayanıklılığının azalmasına yol açar. Bu bozulma süreçlerinin anlaşılması, yapıların dayanıklılığının değerlendirilmesi ve kalan faydalı kullanım ömrünün (Remaining Service Life - RSL) tahmin edilmesi, bakım ve onarım stratejilerinin planlanması, güvenlik risklerinin yönetilmesi ve ekonomik kayıpların önlenmesi açısından büyük önem taşır. YZ/MÖ, malzeme özellikleri, çevresel koşullar, yükleme geçmişi ve mevcut hasar durumu gibi çok sayıda faktörü dikkate alarak beton yapıların gelecekteki davranışlarını ve bozulma hızlarını modelleyebilir ve böylece dayanıklılık performansları ile RSL tahminlerini iyileştirebilir [12].

YZ güdümlü kestirimci bakım (predictive maintenance) yaklaşımları, yapıların ömrünü uzatma ve bakım maliyetlerini düşürme potansiyeline sahiptir. Akıllı beton yapılarda (örneğin, gömülü sensörlerle donatılmış yapılar) YZ güdümlü kestirimci bakım stratejilerinin uygulanmasının, yapıların kullanım ömrünü %20'ye kadar uzatabileceğini ve bakım maliyetlerini %15'e kadar azaltabileceğini göstermektedir [13]. Bu sistemler, sensörlerden gelen gerçek zamanlı verileri analiz ederek bozulma

örüntülerini öğrenir, potansiyel arızaları veya hasarları önceden tahmin eder ve bakım faaliyetlerinin en uygun zamanda planlanmasını sağlar. Bu, sadece ekonomik fayda sağlamakla kalmaz, aynı zamanda yapısal güvenliği artırır ve kaynakların daha verimli kullanılmasına olanak tanır.

3.5. Üretim Süreçlerinde Kalite Kontrol ve Verimlilik Artışı

Beton üretimi, ham maddelerin temininden karıştırılmasına, taşınmasından yerleştirilmesine ve kürlenmesine kadar birçok aşamayı içeren karmaşık bir süreçtir. Bu sürecin herhangi bir aşamasındaki değişkenlikler veya hatalar, nihai betonun kalitesini ve performansını olumsuz etkileyebilir. YZ/MÖ, beton üretim süreçlerinin çeşitli aşamalarında kalite kontrolünü otomatikleştirmek, tutarlılığı sağlamak, verimliliği artırmak ve maliyetleri düşürmek için güçlü araçlar sunmaktadır [1].

Çimento üretiminde, YZ/MÖ, fırın operasyonlarını optimize ederek enerji tüketimini ve dolayısıyla CO_2 emisyonlarını azaltabilir, ham maddelerin daha verimli kullanılmasını sağlayabilir ve nihai ürünün kalite tutarlılığını artırabilir [14]. Hazır beton tesislerinde ve şantiyelerde YZ, karışım oranlarının gerçek zamanlı olarak ayarlanmasına (örneğin, gelen agregaların nem içeriğine veya ortam sıcaklığına göre), sevkiyat lojistiğinin optimize edilmesine ve müşteri deneyiminin iyileştirilmesine yardımcı olabilir [15]. Sıcaklık ve neme dayalı gerçek zamanlı karışım ayarlamaları, şantiyede reddedilen beton yüklerini önleyerek hem malzeme israfını hem de zaman kaybını azaltabilir.

Prekast beton üretim tesislerinde YZ, üretim hattındaki elemanların kalitesini (çatlak, dökülme, boyutsal uygunluk vb.) görüntü işleme ve sensör verilerini analiz ederek otomatik olarak kontrol edebilir, üretim programlarını ve kaynak tahsisini optimize ederek verimliliği artırabilir ve ekipman arızalarını önceden tahmin ederek plansız duruş sürelerini azaltabilir [16]. Bu tür uygulamalar, üretim süreçlerinde insan hatasını azaltır, ürün kalitesini standartlaştırır ve genel operasyonel mükemmelliğe katkıda bulunur.

3.6. Beton Kıvamının (Slamp) Yapay Zekâ ile Takibi

Betonun işlenebilirliğinin ve kalitesinin en önemli göstergelerinden biri olan kıvam, şantiyede başarılı bir döküm için kritik öneme sahiptir. Geleneksel çökme (slamp) deneyi, zaman alıcı olması, operatör

becerisine bağlı sonuçlar vermesi ve sadece anlık bir ölçüm sunması gibi dezavantajlara sahiptir. Yapay zekâ destekli sensör teknolojileri ve görüntü işleme teknikleri, bu zorlukların üstesinden gelerek beton kıvamının transmikser içerisinde veya döküm sırasında sürekli, objektif ve gerçek zamanlı olarak izlenmesine olanak tanımaktadır.

Transmikser içine veya üzerine yerleştirilen çeşitli sensörlerden toplanan veriler, yapay zekâ algoritmalarıyla analiz edilerek betonun kıvamı, sıcaklığı, hacmi ve diğer reolojik özellikleri hakkında değerli bilgiler sağlar. Bu sistemler, beton şantiyeye ulaşmadan önce veya döküm sırasında kalitede sapma olması durumunda gerekli ayarlamaların (örneğin, kimyasal katkı ilavesi) yapılmasına imkân tanır. Bu proaktif yaklaşım, beton kalitesinde tutarlılık ve güvenilirlik sağlayarak, geleneksel yöntemlerin reaktif doğasının önüne geçer.

Hidrolik Basınç, Tork ve Devir (RPM) Bazlı Sistemler

Bu sistemlerin temel prensibi, transmikser tamburunu döndürmek için gereken mekanik gücün, içindeki betonun reolojik özellikleriyle (özellikle akma gerilmesi ve plastik viskozitesi) doğrudan ilişkili olmasına dayanır. Betonun kıvamı değiştikçe, yani daha akışkan veya daha katı hâle geldikçe, tamburu belirli bir hızda (RPM) döndürmek için gereken hidrolik basınç (hidrolik motorlarda) veya elektrik motor torku da değişir. Bu sensörler, mevcut transmikser sistemlerine nispeten kolay entegre edilebilir olmaları ve betonun reolojik özelliklerindeki değişimlere karşı duyarlı olmaları nedeniyle dikkat çekmektedir.

Toplanan hidrolik basınç, motor torku ve tambur devir hızı (RPM) verileri, yapay zekâ (özellikle makine öğrenmesi) modelleri için girdi olarak kullanılır. Bu modeller, sensör verileri ile laboratuvarda veya sahada standart yöntemlerle (örn, çökme deneyi) ölçülen kıvam değerleri arasındaki karmaşık ve genellikle doğrusal olmayan korelasyonları öğrenir. Yeterli miktarda ve çeşitlilikte veri ile eğitildikten sonra, bu modeller yeni sensör verilerinden yola çıkarak betonun anlık kıvam değerini yüksek bir doğrulukla tahmin edebilir.

Akustik Sensörler ve Ses Analizi ile Kıvam Belirleme

Akustik sensörler, betonun karıştırılması ve transmikser tamburu içinde hareket etmesi sırasında oluşan sesleri ve titreşimleri algılayarak kıvam hakkında bilgi toplar. Bu sensörler, genellikle piezoelektrik malzemelerden (örn: PVDF yamaları, PZT seramikleri) yapılmış olup, tamburun iç veya dış duvarına monte edilebilir. Temel fikir, betonun kıvamındaki değişikliklerin (örneğin, düşük slamp değerine sahip katı bir betonun tambur içinde "topaklanarak" düşmesi ile yüksek slamp değerine sahip akışkan bir betonun daha "yumuşak" ve sürekli bir ses çıkarması) farklı akustik imzalar yaratacağıdır [17]. Akustik sensörler, betonun iç yapısındaki ve akış davranışındaki bu ince değişikliklere karşı hassas olabilir ve invaziv olmayan (betona doğrudan temas etmeyen) bir ölçüm yöntemi sunabilir.

Toplanan ham akustik sinyaller genellikle karmaşık ve gürültülüdür. Yapay zekâ, özellikle makine öğrenmesi ve sinyal işleme teknikleri, bu verilerden anlamlı örüntüleri çıkarmak için kullanılır. AI algoritmaları, farklı kıvam değerleriyle ilişkilendirilmiş akustik veri setleri üzerinde eğitilerek, belirli ses frekansları, genlikleri veya zaman içindeki değişim örüntüleri ile beton kıvamı arasında bir bağlantı kurar [18]. Bu eğitim süreci tamamlandıktan sonra, sistem yeni akustik verileri analiz ederek betonun anlık kıvam değerini tahmin edebilir. Akustik AI, sadece kıvam tahmini yapmakla kalmayıp, aynı zamanda ses verisi eşleştirme, analiz ve akustik teşhis yoluyla karıştırma ekipmanlarındaki potansiyel sorunları (örneğin, yatak aşınması) belirlemeye de yardımcı olabilir [19].

Viskozite Sensörleri ile Sürekli Kıvam İzleme

Betonun viskozitesi, işlenebilirliği ve dolayısıyla kıvam değeri ile yakından ilişkilidir. Viskozite, bir akışkanın akmaya karşı gösterdiği iç direncin bir ölçüsüdür. Inline (hat içi) viskozite sensörleri, transmikser tamburu içindeki beton karışımının viskozitesini ve bazen de yoğunluğunu sürekli ve gerçek zamanlı olarak ölçmek için tasarlanmıştır [20]. Bu sensörler, genellikle betonla doğrudan temas hâlinde çalışır. Viskozite, betonun akış davranışını belirleyen temel bir reolojik özellik olduğu için, sürekli viskozite izleme, kıvamdaki en ufak değişikliklerin bile anında tespit edilmesini sağlar.

Gerçek zamanlı olarak toplanan viskozite, yoğunluk ve sıcaklık verileri, bir yapay zekâ modeline girdi olarak verilebilir. Bu AI modeli, bu sensör verileri ile bilinen slamp değerleri veya işlenebilirlik parametreleri arasındaki ilişkiyi öğrenerek, anlık kıvam tahminleri yapabilir. Geçmiş verilere dayalı olarak bir "beklenen süreç zarfı" (expected process envelope) oluşturularak, karıştırma veya taşıma sırasında viskozite gelişiminin normal sınırlar içinde olup olmadığı sürekli olarak izlenebilir. Herhangi bir sapma durumunda, AI sistemi operatörü uyarabilir veya otomatik olarak düzeltici eylemler (örneğin, katkı maddesi dozajının ayarlanması) önerebilir [20]. Yapay zekâ, bu viskozite verilerini karışım tasarımı detayları, kullanılan katkı maddeleri ve ortam koşulları gibi diğer ilgili parametrelerle birleştirerek daha doğru ve kapsamlı tahminler yapma potansiyeline sahiptir.

Görüntü İşleme ve Bilgisayarlı Görü ile Kıvam Tahmini

Bu yaklaşımda, transmikserin içine veya betonun döküldüğü noktaya (örneğin, boşaltma oluğu) yerleştirilen kameralar kullanılır. Bu kameralar, standart RGB (renkli) kameralar olabileceği gibi, derinlik bilgisi de sağlayan RGB-D kameralar da olabilir. Kameralar, betonun yüzey görünümünü, akışkanlığını, yığılma şeklini ve karıştırma sırasındaki hareketlerini sürekli olarak kaydeder. Görüntü işleme teknikleri, betonun fiziksel görünümündeki ve davranışındaki bu ince değişiklikleri doğrudan yakalayarak kıvamı hakkında değerli ve kantitatif bilgiler sunar [21].

Toplanan görüntüler, yapay zekâ, özellikle de derin öğrenme algoritmaları (en yaygın olarak CNN'ler) ve görüntü tanıma teknolojileri tarafından analiz edilir. Bu AI sistemleri, geniş bir görüntü veri seti (farklı kıvamlardaki betonların görüntüleri) ve bu görüntülere karşılık gelen doğrulanmış slamp ölçümleri (etiketler) kullanılarak eğitilir. Eğitim süreci sonunda AI modeli, betonun yoğurma veya akma sırasındaki görsel desenleri ile slamp değeri arasında bir ilişki kurmayı öğrenir. Daha sonra, sistem yeni ve daha önce görmediği beton görüntülerini analiz ederek slamp değerini gerçek zamanlı olarak tahmin edebilir [21]. RGB-D (derinlik sensörlü) kameralardan elde edilen veriler, sadece renk bilgisi (RGB) içeren standart kamera görüntülerine kıyasla daha iyi performans gösterebilir. Bunun nedeni, derinlik bilgisinin betonun yığılma geometrisi, yüzey pürüzlülüğü ve akış profili hakkında ek ve değerli üç boyutlu veriler sağlamasıdır [22].

3.7. Hazır Beton Nakliyesinde Yapay Zekâ Uygulamaları

Hazır betonun kalitesi, üretim tesisinden şantiyeye kadar olan nakliye sürecinin etkinliğine büyük ölçüde bağlıdır. Bu süreçte karşılaşılan zorluklar, yapay zekâ tabanlı çözümlerle önemli ölçüde azaltılabilmektedir. Yapay zekâ, lojistik optimizasyonundan filo yönetimine kadar geniş bir yelpazede uygulanarak hem maliyetleri düşürmekte hem de operasyonel verimliliği artırmaktadır.

Lojistik Optimizasyonu ve Akıllı Rota Planlama

Hazır beton gibi zaman açısından son derece hassas bir ürünün taşınmasında lojistik optimizasyonu hayati önem taşır. Betonun üretiminden itibaren yaklaşık 2 saatlik bir kullanım ömrü olduğu göz önüne alındığında, en kısa ve en verimli rotanın seçilmesi, betonun kalitesini korumak ve israfı önlemek için kritik bir faktördür.

- **Dinamik Rota Optimizasyonu:** Yapay zekâ algoritmaları, bu ihtiyaca cevap vermek üzere geliştirilmiştir. Bu algoritmalar, trafik yoğunluğu, hava durumu tahminleri, yol yapım çalışmaları veya ani yol kapanmaları gibi çok sayıda gerçek zamanlı veriyi analiz ederek teslimat rotalarını anlık olarak ve sürekli bir şekilde ayarlar. Bu dinamik yaklaşım, yakıt tüketimini minimize eder, teslimat sürelerini optimize eder ve beklenmedik operasyonel kesintilerin önüne geçer. Böylece, betonun şantiyeye optimum sürede ve kalitede ulaşması sağlanır, bu da reddedilen yükleri ve kalite sorunlarını azaltır. Bu durum, yapay zekânın lojistik verimliliğinin ötesinde, doğrudan ürün kalitesine ve dolayısıyla müşteri memnuniyetine etki ettiğini göstermektedir.
- **Gerçek Zamanlı Veri Analizi:** Akıllı rota planlamasının temelini, GPS teknolojisi, trafik yönetim sistemleri ve araçlara entegre edilmiş sensörlerden elde edilen verilerin yapay zekâ tarafından anlık olarak işlenmesi oluşturur. Bu sürekli veri akışı, sürücülerin her zaman en uygun rotayı takip etmelerini ve olası gecikmelere karşı proaktif bir şekilde adapte olmalarını sağlar. Şantiyelerdeki bekleme süreleri, trafik sıkışıklığı gibi faktörler betonun kalitesini olumsuz etkileyebileceğinden, gerçek zamanlı veri analizi bu tür durumların önceden tespit edilip gerekli önlemlerin alınmasına olanak tanır.
- **Rota Optimizasyonunda Dikkate Alınan Faktörler:** Yapay zekâ destekli rota optimizasyon sistemleri, sadece mesafeyi değil, aynı zamanda transmikserlerin büyük boyutları ve sınırlı manevra kabiliyetleri için önemli olan dar dönüşler, karmaşık kavşaklar, en uygun veya en yakın sürücünün atanması, anlık trafik durumu ve şantiyeye kolay erişim gibi birçok faktörü göz önünde bulundurur. Bu detaylı analiz hem zaman kaybını önler hem de kaza riskini azaltır.

Transmikser Filo Yönetimi ve Gerçek Zamanlı İzleme

Hazır beton lojistiğinde verimliliğin bir diğer önemli unsuru da transmikser filosunun etkin yönetimidir. Yapay zekâ ve Nesnelerin İnterneti (IoT) teknolojileri, bu alanda da önemli iyileştirmeler sunmaktadır.

- **Araç Takibi ve Durum İzleme:** IoT entegrasyonu sayesinde, transmikserlerin konumu, hızı, anlık yakıt tüketimi, tambur dönüş hızı ve yönü gibi kritik operasyonel veriler gerçek zamanlı olarak izlenebilir. Bu sürekli veri akışı, filo yöneticilerine operasyonlar hakkında anlık ve kapsamlı bir görünüm sunarak proaktif karar almalarını sağlar. Gerçek zamanlı izleme, araç arızası, yanlış tambur hızı gibi olası sorunların anında tespit edilip müdahale edilmesini mümkün kılar, böylece beton kalitesi korunur ve operasyonel aksamalar minimuma indirilir.
- **Öngörücü Bakım:** Transmikserlerden toplanan sensör verileri (motor sıcaklığı, hidrolik basınç, titreşim vb.), makine öğrenmesi modelleri tarafından analiz edilerek potansiyel arızaların henüz oluşmadan önce tahmin edilmesi mümkündür. Bu öngörücü bakım yaklaşımı, plansız duruş sürelerini ve buna bağlı bakım maliyetlerini önemli ölçüde azaltırken, aynı zamanda ekipmanın genel ömrünü uzatır. Transmikser arızalarının beton teslimatlarında ciddi gecikmelere ve mali kayıplara yol açabileceği düşünüldüğünde, öngörücü bakımın önemi daha da artmaktadır.
- **Kaynak Atama ve Optimizasyonu:** Yapay zekâ, gelen siparişlere ve şantiye taleplerine göre en uygun aracın ve sürücünün otomatik olarak atanmasını, taşınacak beton miktarının optimize edilmesini ve araçların boş dönüşlerinin azaltılmasını sağlar. Örneğin, ThroughPut AI gibi platformlar, seyahat süreleri, dönüş yolculukları, şantiye içi bekleme süreleri ve müşteri geri arama oranları gibi verileri analiz ederek kamyon sevklerini en yakın ve en uygun üretim tesisine yönlendirme, dönüş sürelerini kısaltma ve hatta yüksek hacimli müşterilere daha yakın yeni tesis lokasyonları belirleme gibi stratejik iyileştirmeler sunabilir. Transmikser filo yönetiminde yapay zekâ kullanımı, sadece tekil araçların verimliliğini artırmakla kalmaz, aynı zamanda tüm tedarik zincirinin esnekliğini ve dayanıklılığını da artırır. Öngörücü bakım sayesinde araçların genel kullanılabilirliğinin artması ve yapay zekâ destekli kaynak atama ile doğru sayıda aracın doğru zamanda doğru yerde bulunması, özellikle ani talep dalgalanmaları veya beklenmedik olaylar (örneğin bir aracın arızalanması) karşısında sistemin daha hızlı ve etkili bir şekilde yanıt verme kapasitesini geliştirir. Gerçek zamanlı izleme ile operasyonel darboğazların hızla tespit edilip çözülmesi, bireysel varlıkların optimizasyonunun ötesinde, tüm sistemin değişen koşullara adaptasyon yeteneğini ve genel direncini artırır.

Otonom Transmikserler: Geleceğe Yönelik Bir Adım

Hazır beton taşımacılığının geleceğinde otonom transmikserler önemli bir yer tutma potansiyeline sahiptir. Otonom kamyon teknolojileri, entegre sensörler (LiDAR, radar, kameralar) ve gelişmiş yapay zekâ algoritmaları kullanarak yollarda insan müdahalesi olmadan gezinme ve sürüş kararları alma yeteneğine sahiptir. Henüz tam otonomi yaygın olarak kullanılmasa da adaptif hız sabitleyici, şerit takip asistanı ve çarpışma önleme sistemleri gibi yarı otonom özellikler günümüz kamyonlarında giderek daha fazla yer bulmaktadır.

- Otonom transmikserlerin yaygınlaşması, birçok önemli faydayı beraberinde getirebilir. Bunların başında artan güvenlik gelmektedir; insan hatası, özellikle yorgunluk kaynaklı kazalar, otonom sistemlerle önemli ölçüde azaltılabilir. Ayrıca, otonom araçlar dinlenme molası ihtiyacı duymadan 7/24 operasyon yapabilme potansiyeline sahip olduklarından, teslimat süreleri kısalabilir ve operasyonel verimlilik artabilir. Yakıt tüketiminin optimizasyonu sayesinde işletme maliyetleri düşebilir ve elektrikli veya hibrit motorlarla entegrasyonları sayesinde çevresel sürdürülebilirlik de artırılabilir. Bu teknolojiler, aynı

zamanda nitelikli sürücü bulma zorluğunun yaşandığı bölgelerde iş gücü eksikliklerinin giderilmesine de katkı sağlayabilir.

- Otonom transmikser teknolojisinin önünde bazı engeller de bulunmaktadır. Bunların başında karmaşık ve henüz tam olarak oturmamış yasal düzenleyici çerçeveler, teknolojinin kamuoyu tarafından kabul görmesi ve özellikle yüksek başlangıç yatırım maliyetleri gelmektedir. Ayrıca, şantiyelerin dinamik ve genellikle zorlu ortamları, otonom araçların navigasyonu için ek zorluklar yaratabilir.

YZ/MÖ'nün beton teknolojisinin bu farklı uygulama alanlarındaki başarısı, büyük ölçüde farklı veri türlerini (sayısal karışım oranları, test sonuçları, görüntüsel çatlak fotoğrafları, mikroyapı görüntüleri; sensör verileri olan sıcaklık, nem, akustik emisyon, titreşim verileri vb.) etkin bir şekilde işleyebilme ve bu çeşitli verilerden anlamlı örüntüler ve ilişkiler çıkarabilme yeteneğine dayanmaktadır. Karışım optimizasyonu genellikle sayısal verilere dayanırken, yapısal sağlık izlemesi ve çatlak tespiti büyük ölçüde görüntü ve sensör verilerine dayanır. Sürdürülebilirlik analizleri ise malzeme özellikleri, çevresel etki metrikleri (örneğin, gömülü karbon, enerji tüketimi) ve maliyet verileri gibi farklı kaynaklardan gelen bilgileri birleştirir. Regresyon modelleri, CNN'ler, Gradyan Artırma Ağaçları (GBT'ler) gibi çeşitli YZ/MÖ algoritmaları, bu farklı veri türlerini işlemek ve bunlardan değerli bilgiler (tahminler, sınıflandırmalar, optimizasyon stratejileri) çıkarmak için özel olarak tasarlanmıştır veya mevcut problemlere uyarlanabilir. Bu durum, YZ/MÖ'nün beton teknolojisi alanındaki çok yönlülüğünü ve geniş uygulama potansiyelini açıkça ortaya koymaktadır.

Günümüzün en önemli küresel sorunlarından biri olan sürdürülebilirlik ve döngüsel ekonomi hedefleri, YZ/MÖ'nün beton teknolojisindeki rolünü sadece bir performans veya maliyet optimizasyon aracı olmaktan çıkarıp, çevresel sorumluluk ve kaynak verimliliği için stratejik bir gereklilik hâline getirmektedir. Beton endüstrisinin yüksek CO_2 emisyonları ve doğal kaynak tüketimi nedeniyle önemli bir çevresel etkiye sahip olduğu bilinmektedir. Sürdürülebilirlik hedefleri, atıkların en aza indirilmesini, geri dönüştürülmüş ve alternatif malzemelerin maksimum düzeyde kullanılmasını ve betonun karbon ayak izinin önemli ölçüde düşürülmesini gerektirir. Bu hedeflere ulaşmak, geleneksel yöntemlerle yönetilmesi son derece karmaşık ve zaman alıcı olabilen çok sayıda değişkenin (malzeme özellikleri, karışım oranları, performans gereksinimleri, üretim maliyeti, çevresel etki vb.) eş zamanlı olarak optimize edilmesini gerektirir. YZ/MÖ, bu tür çok amaçlı optimizasyon problemlerini çözmede, yenilikçi, çevre dostu ve aynı zamanda yüksek performanslı beton formülasyonları geliştirmede üstün bir yetenek sergilemektedir. Dolayısıyla, YZ/MÖ, beton endüstrisinin karşı karşıya olduğu bu kritik sürdürülebilirlik zorluklarına etkili yanıtlar vermesinde merkezi bir rol oynamaktadır. Bu teknolojiler, sadece daha iyi performanslı beton üretmekle kalmaz, aynı zamanda bu betonun gezegenimiz için daha sorumlu ve sürdürülebilir bir şekilde üretilmesine de olanak tanır. Bu durum, YZ/MÖ'nün beton teknolojisinde benimsenmesi ve yaygınlaştırılması için güçlü bir etik ve ekonomik gerekçe sunmaktadır.

5. Karşılaşılan Zorluklar ve Sınırlamalar

Yapay zekâ ve makine öğreniminin beton teknolojisine sunduğu muazzam potansiyele rağmen, bu teknolojilerin yaygın ve sorunsuz bir şekilde benimsenmesinin önünde önemli zorluklar ve sınırlamalar bulunmaktadır. Bu engellerin anlaşılması, gelecekteki araştırma ve geliştirme çabalarının doğru yönlendirilmesi ve pratik çözümler üretilmesi açısından kritik öneme sahiptir.

- **Veri Erişimi, Kalitesi ve Miktarı:** YZ/MÖ modellerinin eğitimi ve doğrulanması için en temel gereksinim, büyük hacimli, çeşitli ve yüksek kaliteli veri setleridir, ancak inşaat sektörü genelinde

ve özel olarak beton teknolojisi alanında, veri toplama, standartlaştırma ve paylaşma kültürü henüz tam anlamıyla gelişmemiştir. Mevcut veri setleri genellikle dağınık, sınırlı sayıda örnek barındıran, gürültülü (hatalı veya eksik ölçümler içeren), tutarsız (farklı test standartları veya koşulları altında elde edilmiş) veya sadece belirli malzeme türleri ya da coğrafi bölgelere özgü olmaktadır. Bu durum, geliştirilen modellerin genelleme yeteneğini (yani, eğitildikleri veri seti dışındaki yeni ve farklı verilere doğru tahmin yapabilme kapasitesini) ciddi şekilde kısıtlamaktadır. Veri temizleme ve aykırı değerlerin yönetimi gibi ön işleme adımları model performansını iyileştirmek için hayati öneme sahiptir, ancak bu adımlar her zaman veri setindeki tüm temel sorunları çözmek için yeterli olmayabilir. Özellikle, yenilikçi beton katkı malzemeleri, geri dönüştürülmüş agregalar veya özel beton türleri (örneğin, geopolimer beton, kendiliğinden iyileşen beton) gibi konularda kapsamlı ve güvenilir deneysel veri bulmak oldukça zor olabilmektedir. Veri ile ilgili bu zorluklar, sadece model performansını değil, aynı zamanda YZ/MÖ'nün beton teknolojisindeki adalet, tarafsızlık ve etik kullanımını da doğrudan etkileyen temel bir sorundur. YZ/MÖ modelleri, eğitildikleri verilerdeki mevcut yanlılıkları (bias) öğrenebilir ve bu yanlılıkları tahminlerine veya kararlarına yansıtabilir **[24].** Eğer mevcut veri setleri belirli malzeme türlerini, üretim pratiklerini veya çevresel koşulları aşırı temsil ediyor veya tam tersine yetersiz temsil ediyorsa, geliştirilen modeller bu dengesizlikleri yansıtarak adil olmayan veya hatalı sonuçlar üretebilir. Örneğin, sadece belirli bir bölgeden toplanan agrega ve çimento verileriyle eğitilmiş bir beton dayanım tahmin modeli, farklı bir coğrafi bölgedeki malzemeler veya iklim koşulları için doğru ve güvenilir tahminler yapamayabilir; bu da kaynakların yanlış yönlendirilmesine, gereksiz maliyetlere veya hatta güvenlik risklerine yol açabilir. Bu nedenle, veri kalitesi ve çeşitliliğinin sağlanması, potansiyel yanlılıkların tespit edilip azaltılması için kritik öneme sahiptir. Beton teknolojisinde YZ/MÖ uygulamalarında veri sorunları, sadece teknik bir performans meselesi olmanın ötesinde, derin etik ve adalet boyutlarını da içermektedir. Kapsayıcı, temsili ve yüksek kaliteli veri setleri oluşturmak, YZ/MÖ'nün beton endüstrisinde sorumlu, güvenilir ve faydalı bir şekilde kullanılmasının vazgeçilmez bir ön koşuludur.

- **Model Yorumlanabilirliği ve Açıklanabilir YZ (XAI) İhtiyacı:** Birçok gelişmiş YZ/MÖ modeli, özellikle Derin Sinir Ağları (DNN'ler) ve karmaşık topluluk modelleri (ensemble models), genellikle "kara kutu" (black box) olarak nitelendirilir. Bu, modellerin son derece doğru tahminler yapabilmesine rağmen, bu tahminlere veya kararlara nasıl ulaştıklarının, yani içsel karar verme mekanizmalarının insanlar tarafından kolayca anlaşılamaması anlamına gelir. Bu durum, özellikle yapısal güvenlik ve dayanıklılığın hayati önem taşıdığı inşaat ve beton teknolojisi sektöründe ciddi bir endişe kaynağıdır **[25].** Eğer bir mühendis, bir YZ modelinin neden belirli bir beton karışımını önerdiğini, bir yapıda neden bir hasar riski öngördüğünü veya bir malzemenin neden belirli bir performansı sergileyeceğini tahmin ettiğini anlayamazsa, o modele güvenmesi ve kritik kararlarını bu tahminlere dayandırması beklenemez. Bu güvensizlik, YZ/MÖ teknolojilerinin endüstriyel ölçekte benimsenmesini ve pratik uygulamalarda yaygınlaşmasını yavaşlatan önemli bir faktördür. YZ/MÖ'nün "kara kutu" doğası ile inşaat endüstrisinin doğası gereği riskten kaçınan ve muhafazakâr yapısı arasındaki bu etkileşim, teknoloji transferini ve pratik uygulamayı yavaşlatan bir tür kısır döngü yaratma potansiyeline sahiptir. Açıklanabilir Yapay Zekâ (Explainable Artificial Intelligence - XAI) teknikleri, bu döngüyü kırmak için kritik bir anahtar sunmaktadır. SHAP (SHapley Additive exPlanations), LIME (Local Interpretable Model-agnostic Explanations) gibi XAI yöntemleri, modelin belirli bir tahmin için hangi girdi özelliklerine ne kadar önem verdiğini, bu özelliklerin tahmini ne yönde etkilediğini ve özellikler arasındaki potansiyel etkileşimleri ortaya koyarak model kararlarını daha şeffaf ve anlaşılır hale getirmeye yardımcı olabilir, ancak XAI tekniklerinin kendileri de hâlâ gelişim aşamasındadır ve özellikle çok

karmaşık modeller için tam bir açıklanabilirlik sağlamak zor olabilir. Bu alanda daha fazla araştırmaya ve kullanıcı dostu XAI araçlarının geliştirilmesine ihtiyaç vardır. Model şeffaflığı (XAI aracılığıyla) artırılmadıkça, endüstrinin YZ/MÖ'ye olan güvensizliği devam edecek ve bu da veri toplama, yatırım yapma ve uzman yetiştirme gibi diğer önemli gelişim alanlarını olumsuz etkileyerek teknolojinin yaygınlaşmasını engelleyecektir. Bu nedenle XAI, sadece teknik bir iyileştirme değil, aynı zamanda YZ/MÖ ile endüstri arasında bir güven köprüsü kuran sosyo-teknik bir gerekliliktir.

- **Endüstrinin YZ/MÖ Teknolojilerini Benimseme Hızı ve Direnç:** İnşaat sektörü, geleneksel olarak dijitalleşme ve yeni teknolojileri benimseme konusunda diğer sektörlere kıyasla daha muhafazakâr ve yavaş bir tutum sergilemektedir. Bu durumun altında yatan birçok neden bulunmaktadır: Projelerin yüksek risk ve maliyet içermesi nedeniyle denenmiş ve test edilmiş yöntemlere olan güçlü bağlılık, her projenin kendine özgü ve değişken olması nedeniyle standart çözümlerin uygulanmasındaki zorluklar, sektörün proje bazlı ve genellikle parçalı bir yapıya sahip olması (farklı paydaşların farklı aşamalarda sorumluluk alması), ve veri paylaşımına yönelik genel bir isteksizlik gibi kültürel ve yapısal engeller, YZ/MÖ gibi yenilikçi teknolojilerin yaygınlaşmasını zorlaştırmaktadır. Bu direncin kırılması, teknolojinin faydalarının somut bir şekilde gösterilmesi, başarılı uygulama örneklerinin yaygınlaştırılması ve endüstri profesyonellerine yönelik eğitim ve farkındalık programlarının artırılması ile mümkün olabilir.
- **Yüksek Başlangıç Maliyetleri ve Uzman Personel İhtiyacı:** YZ/MÖ sistemlerinin geliştirilmesi, uygulanması ve sürdürülebilir bir şekilde bakımı; uygun veri toplama altyapısının kurulması, gelişmiş yazılımların ve donanımların tedarik edilmesi ve en önemlisi bu sistemleri tasarlayacak, eğitecek, yönetecek ve yorumlayacak yetenekli veri bilimcileri, YZ uzmanları ve saha bilgisine sahip mühendisler gibi kalifiye personel istihdamını gerektirir. Tüm bunlar, özellikle küçük ve orta ölçekli işletmeler için önemli bir engel teşkil edebilecek yüksek başlangıç maliyetleri anlamına gelmektedir. Ayrıca hem inşaat sektöründe hem de genel olarak YZ/MÖ alanında yetenekli uzman açığı bulunmaktadır, bu da uygun personeli bulmayı ve elde tutmayı zorlaştırmaktadır.
- **Standardizasyon ve Regülasyon Eksikliği:** Beton teknolojisinde YZ/MÖ uygulamaları için henüz tam olarak oluşturulmuş standartlaştırılmış veri formatları, test protokolleri, model doğrulama prosedürleri ve performans değerlendirme yönergeleri bulunmamaktadır. Bu durum, farklı araştırmacılar veya kurumlar tarafından geliştirilen modellerin ve elde edilen sonuçların birbirleriyle karşılaştırılmasını, doğrulanmasını ve genelleştirilmesini zorlaştırmaktadır. Mevcut tahribatsız muayene (NDT) standartları (örneğin, ASTM, ACI, EN, ISO tarafından yayımlananlar) da henüz YZ/MÖ tekniklerinin entegrasyonunu ve bu tekniklerle elde edilen sonuçların nasıl yorumlanacağını tam olarak ele almamaktadır. Bu belirsizlikler, teknolojinin endüstriyel kabulünü ve güvenilirliğini olumsuz etkileyebilir.
- **Teknik Sınırlamalar ve Aşırı Uyma (Overfitting) Riski:** YZ/MÖ modelleri, özellikle eğitim için kullanılan veri seti sınırlı, gürültülü veya belirli bir problemi tam olarak temsil etmiyorsa, "aşırı uyma" (overfitting) riskine yatkındır. Aşırı uyma, modelin eğitim verilerindeki örüntüleri ve gürültüyü ezberlemesi, ancak yeni ve daha önce görmediği veriler üzerinde düşük tahmin performansı sergilemesi durumudur. Bu, modelin gerçek dünya uygulamalarında güvenilir olmamasına yol açar. Ayrıca, laboratuvar koşullarında belirli bir malzeme seti ve test prosedürü ile geliştirilen bir modelin, farklı malzeme kaynakları, farklı çevresel koşullar (sıcaklık, nem), farklı inşaat pratikleri veya farklı yapı tipleri arasında genelleştirilmesi, yani benzer bir doğrulukla çalışması genellikle zordur. Bu genelleme sorunu, YZ/MÖ modellerinin pratik değerini sınırlayan önemli bir teknik engeldir.

6. Sonuç

Bu rapor, beton teknolojisi alanında yapay zekâ (YZ) ve makine öğreniminin (MÖ) artan rolünü, mevcut uygulamalarını, karşılaşılan zorlukları ve gelecekteki potansiyelini kapsamlı bir şekilde incelemiştir. Elde edilen bulgular, YZ/MÖ'nün beton endüstrisinde önemli dönüşümler yaratma kapasitesine sahip olduğunu açıkça ortaya koymaktadır.

- YZ/MÖ teknikleri, beton karışım tasarımının optimizasyonu, taze ve sertleşmiş beton özelliklerinin (basınç dayanımı, işlenebilirlik vb.) doğru bir şekilde tahmin edilmesi, yapısal sağlık izlemesi yoluyla hasarların (özellikle çatlakların) erken tespiti ve sınıflandırılması, beton dayanıklılığının ve kalan kullanım ömrünün değerlendirilmesi, üretim süreçlerinde kalite kontrolünün artırılması ve sürdürülebilir beton uygulamalarının (düşük karbonlu beton geliştirme, atık malzemelerin kullanımı) teşvik edilmesi gibi beton teknolojisinin birçok kritik alanında önemli faydalar sağlamaktadır. Bu uygulamalar, çok sayıda akademik çalışma ve bazı endüstriyel pilot projelerle desteklenmektedir.
- Bu teknolojilerin kullanımı, malzeme geliştirme ve test süreçlerinde önemli ölçüde zaman ve maliyet tasarrufu sağlama, beton performansını ve kalitesini artırma, yapıların güvenliğini ve ömrünü uzatma ve daha çevre dostu, sürdürülebilir inşaat çözümleri geliştirme potansiyeline sahiptir.
- YZ/MÖ'nün beton teknolojisinde yaygın olarak benimsenmesinin önünde önemli engeller bulunmaktadır. Bunlar arasında en belirgin olanları; büyük, çeşitli ve yüksek kaliteli veri setlerine erişimdeki zorluklar ve veri paylaşımındaki isteksizlik; birçok YZ/MÖ modelinin (özellikle derin öğrenme modellerinin) kararlarının yorumlanmasındaki güçlükler ve buna bağlı güven eksikliği; inşaat sektörünün yeni teknolojilere adaptasyonundaki genel yavaşlık ve kültürel direnç; YZ/MÖ sistemlerinin geliştirilmesi ve uygulanması için gereken yüksek başlangıç maliyetleri ve kalifiye uzman personel eksikliği; ve son olarak, veri formatları, model doğrulama prosedürleri ve etik kullanım konularında standartlaşma ve regülasyon eksikliğidir.

Yapay zekâ ve makine öğrenimi, beton teknolojisinde bir devrim yaratma potansiyeline sahiptir. Bu teknolojiler, betonun tasarımından üretimine, uygulanmasından ömrünün sonuna kadar olan tüm yaşam döngüsünü daha akıllı, daha verimli, daha güvenli ve daha sürdürülebilir hâle getirme vaadi taşımaktadır. Gelecekte, YZ/MÖ'nün, malzeme bilimindeki temel anlayışımızı derinleştirmesi, tamamen yeni ve üstün özelliklere sahip betonların keşfedilmesini sağlaması, otonom inşaat süreçlerini yönlendirmesi ve yapıların kendi kendilerini izleyip onarabilen "akıllı" sistemlere dönüşmesine katkıda bulunması beklenmektedir, ancak bu heyecan verici potansiyelin tam olarak gerçekleştirilebilmesi için, mevcut zorlukların üstesinden gelinmesi ve belirlenen önerilerin hayata geçirilmesi gerekmektedir. Bu, sadece daha gelişmiş algoritmalar ve daha güçlü hesaplama kaynakları geliştirmekle sınırlı kalmamalı; aynı zamanda veri altyapılarının iyileştirilmesi, açıklanabilir ve güvenilir YZ sistemlerinin tasarlanması, endüstriyel standartların ve etik kuralların oluşturulması, multidisipliner iş birliklerinin güçlendirilmesi ve en önemlisi insan kaynağının bu yeni teknoloji çağına hazırlanması gibi çok boyutlu çabaları içermelidir.

Sonuç olarak, beton teknolojisinde yapay zekâ ve makine öğreniminin rolü giderek artacak ve bu alandaki inovasyonun temel itici güçlerinden biri olmaya devam edecektir. Teknolojinin sorumlu, etik ve insan odaklı bir yaklaşımla benimsenmesi ve geliştirilmesi, beton endüstrisinin gelecekteki zorluklara daha etkin bir şekilde yanıt vermesini ve toplum için daha değerli, dayanıklı ve sürdürülebilir yapılar inşa etmesini sağlayacaktır. Bu yolda devam eden araştırma, geliştirme, eğitim ve iş birliği çabaları, YZ/MÖ'nün sunduğu fırsatları en üst düzeye çıkarmak için hayati öneme sahiptir.

Kaynaklar:

1. Ahmed, H. Q., Umm E. H., Muhammed, A. S., Koç, M., & Mosbeh, R. K. (2023). Machine learning in concrete technology: A review of current researches, trends, and applications. ResearchGate. https://www.researchgate.net/publication/368575926_Machine_learning_in_concrete_technology_A_review_of_current_researches_trends_and_applications
2. Azuaje, Francisco & Witten, Ian & E, Frank. (2006). Witten IH, Frank E: Data Mining: Practical Machine Learning Tools and Techniques. Biomedical Engineering Online - BIOMED ENG ONLINE. 5. 1-2.
3. Nikoopayan Tak, M. S., Feng, Y., & Mahgoub, M. (2025). Advanced Machine Learning Techniques for Predicting Concrete Compressive Strength. Infrastructures, 10(2), 26. https://doi.org/10.3390/infrastructures10020026
4. Datta, Shuvo & Islam, Mobasshira & Sobuz, Md. Habibur & Ahmed, Shakil & Kar, Moumita. (2024). Artificial intelligence and machine learning applications in the project lifecycle of the construction industry: A comprehensive review. Heliyon. 10.1016/j.heliyon.2024.e26888.
5. Hadi Salehi, Rigoberto Burgueño, Emerging artificial intelligence methods in structural engineering, Engineering Structures, Volume 171, 2018, Pages 170-189, ISSN 0141-0296, https://doi.org/10.1016/j.engstruct.2018.05.084.
6. A. Adadi and M. Berrada, "Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI)," in IEEE Access, vol. 6, pp. 52138-52160, 2018, doi:10.1109/ACCESS.2018.2870052.
7. Li, F., Rana, M.S. & Qurashi, M.A. Advanced machine learning techniques for predicting concrete mechanical properties: a comprehensive review of models and methodologies. Multiscale and Multidiscip. Model. Exp. and Des. **8**, 110 (2025). https://doi.org/10.1007/s41939-024-00672-4
8. Marchewka A, Ziolkowski P, García Galán S. Real-time prediction of early concrete compressive strength using AI and hydration monitoring. Sci Rep. 2025 May 2;15(1):15463. doi: 10.1038/s41598-025-97060-w. PMID: 40316640; PMCID: PMC12048722.
9. Kaustav Sarkar, Amit Shiuly, Krishna Gopal Dhal, Revolutionizing concrete analysis: An in-depth survey of AI-powered insights with image-centric approaches on comprehensive quality control, advanced crack detection and concrete property exploration, Construction and Building Materials, Volume 411, 2024, 134212, ISSN 0950-0618, https://doi.org/10.1016/j.conbuildmat.2023.134212.
10. Alkhraisha, M., Al-Bodour, W., Al-Qadi, M., Alazaizeh, M., & Al-Mistarehi, B. (2024). Drexel Researchers Propose AI-Guided System for Robotic Inspection of Buildings, Roads and Bridges. Drexel University News. https://drexel.edu/news/archive/2024/January/AI-robotic-crack-detection-monitoring
11. FPrimeC Solutions Inc. (2025). 5 ways AI is revolutionizing the NDT of Concrete. https://fprimec.com/5-ways-ai-is-revolutionizing-the-ndt-of-concrete/

12. Saleem, H., & Kim, Y. (2023). "A state-of-the-art review on the prediction of concrete durability and service life using artificial intelligence". Construction and Building Materials, 366, 130248.
13. North American Academic Research. (2025). Integration of AI-Driven Predictive Maintenance in Smart Concrete Structures to Enhance Sustainability and Lifecycle Efficiency. Zenodo. https://doi.org/10.5281/zenodo.14840495
14. Basetwo AI. (2024). Efficient and High-Quality Cement Manufacturing with AI. https://www.basetwo.ai/blogs/cement-manufacturing-improved-with-ai
15. EROAD USA. (2025). 5 Ways AI is Reshaping How Ready-Mix Fleets Operate. https://www.eroad.com/blog/5-ways-ai-is-reshaping-how-ready-mix-fleets-operate/
16. BFT International. (2024, February 20). Unlocking the Future of Precast Concrete Manufacturing with AI. https://www.bft-international.com/en/news/unlocking-the-future-of-precast-concrete-manufacturing-with-ai-4061087.html
17. https://trea.com/information/techniques-for-monitoring-slump-characteristic-of-concrete-in-a-rotating-contain/patentgrant/b7437d97-180a-4aa3-9a26-651b91a3f687
18. Agarwal, Vivek, Miele, Sarah, Karave, Pranav, & Mahadevan, Sankaran (2020). Concrete Structure Health Monitoring Using Vibro-acoustic Testing and Machine Learning, U.S. Department of Energy Office of Nuclear Energy, 2020. https://doi.org/10.2172/2448466
19. https://www.mtrlab.com.hk/en/news/enabling-predictive-maintenance-with-acoustic-ai/
20. https://tr.rheonics.com/solutions-item/mixing-vessels-monitoring-and-controlling-the-mixing-efficiency/
21. Masatoshi Kudo, Predicting the Slump of Concrete Using an Artificial Intelligence System, https://www.jsce.or.jp/committee/concrete/e/newsletter/newsletter73/Newsletter%2073_files/2.pdf
22. Chen, H., Yang, J., Fang, H., Wu, S., & Lin, B. (2024). Prediction of concrete slump by RGB-D image feature fusion. Computers and Concrete, 34(5), 535–546. https://doi.org/10.12989/CAC.2024.34.5.535
23. Adeoye, Yetunde & Onotole, Erumusele & Ogunyankinnu, Tunde & Aipoh, Godwin & Osunkanmibi, Akintunde & Egbemhenghe, Joseph. (2025). Artificial Intelligence in Logistics and Distribution: The function of AI in dynamic route planning for transportation, including self-driving trucks and drone delivery systems. World Journal of Advanced Research and Reviews. 25. 155-167. 10.30574/wjarr.2025.25.2.0214.
24. S. Barbhuiya and M. S. Sharif, "Artificial Intelligence in Concrete Mix Design: Advances, Applications and Challenges," 2023 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT), Sakheer, Bahrain, 2023, pp. 32-37, doi: 10.1109/3ICT60104.2023.10391485.
25. Kalasampath, Khushi & KN, Spoorthi & Sajeev, Sreeparvathy & Kuppa, Sahil & Ajay, Kavya & Angulakshmi, M. (2025). A Literature Review on Applications of Explainable Artificial Intelligence (XAI). IEEE Access. PP. 1-1. 10.1109/ACCESS.2025.3546681.

www.thbb.org

www.thbbakademi.org