



Yapım İşlerinde İhale Parametreleri Kullanılarak Makine Öğrenmesi ile Sözleşme Bedeli Tahmini

Construction Contract Price Prediction Using Machine Learning with Bidding Parameters

Semi Emrah Aslay* 

Erzincan Binali Yıldırım Üniversitesi, Mühendislik Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Erzincan, Türkiye

Öz

Kamu ihalelerinde sözleşme bedelleri, temel olarak metraj ve birim fiyatlardan oluşmaktadır ve dolayısıyla bu parametrelerle yakından ilişkilidir. Bu parametrelerden başka, daha sade sayısal ifadeler üretebilen ve parasal anlaşma bedelleri hakkında önemli ipuçları veren ihale verileri de anlamlı ilişkilere sahiptir. Dolayısıyla ihale verileri ile sözleşme bedeli arasındaki anlamlı ilişkinin değerlendirilmesi önem kazanmaktadır. Bu çalışmada inşaat işlerinde ihale değişkenleri kullanılarak makine öğrenmesi yöntemleri ile sözleşme bedelleri tahmin edilmeye çalışılmaktadır. Bunun için temel ve popüler algoritmalarından yararlanılmıştır. Tahmin modellerini geliştirmek amacıyla bir dizi hiper parametre optimizasyonu yapılarak olumlu sonuçlar alınmıştır. Özellikle çalışmada en iyi sonuçlara sahip olan XGBoost ve ANN algoritmalarında uygulanan parametrik optimizasyonlar, mevcut modelin daha iyi bir performansı göstermesini sağlamıştır. XGBoost 0.9435, MAE 1.2988, RMSE 2.0621 en iyi genelleme yeteneğine sahip algoritma olmuştur. Çalışma hem kullandığı parametrelerin özgünlüğü hem de makine öğrenmesi modelinde uygulanan hiper parametre optimizasyonları ile literatüre katkı sunmaktadır.

Anahtar Kelimeler: ANN, kamu ihaleleri, makine öğrenmesi, sözleşme bedeli, XGBoost.

Abstract

In public tenders, contract values are primarily composed of quantities and unit prices, and therefore are closely related to these parameters. Besides these parameters, contract values are also meaningfully associated with procurement data that can produce more straightforward numerical expressions and provide significant insights into monetary agreement values. Therefore, evaluating the meaningful relationship between procurement data and contract value becomes crucial. This study aims to predict contract amounts in construction works using machine learning methods with bidding variables. Basic and popular algorithms were employed for this purpose. A series of hyperparameter optimizations were conducted to enhance prediction models, yielding positive results. Particularly, the parametric optimizations applied to XGBoost and ANN algorithms, which demonstrated the best results in the study, improved the performance of the existing model. XGBoost achieved the best generalization ability with an R^2 of 0.9435, MAE of 1.2988, and RMSE of 2.0621. The study contributes to the literature by introducing novel parameters and implementing hyperparameter optimizations in the machine learning model.

Keywords: ANN, public tenders, machine learning, contract price, XGBoost.

1. Giriş

Yapım işlerinde kamu kurumlarına ait binalar, yüklenici firmalara ihale edilerek yapılmaktadır.

İhale süreçleri rekabetçilik ve eşitlik ilkelerine dayanarak en uygun fiyatla, istenilen yapıların inşa edilmesini kapsar. Ku-

rumlar veya harcama yetkilileri farklı kullanım amacı için, insanların ihtiyaçlarını karşılayacak yapıların tanımını, tarifini belirler, yasalara ve yönetmeliklere göre süreci yönetir. Bu süreç açık bir şekilde duyurulur ve yüklenici firmalar kâr-zarar oranlarını gözeterek ihale teklif sürecine girer. İhalelere katılan inşaat firmaları, istekli veya teklif verenler olarak adlandırılırlar. Teklif verenlere ait bilgiler ihale süreçlerinde önemli göstergelerden biridir. Toplam tekliflerin sayısal ifadeleri inşaat işlerine olan ilgiyi, yoğunluğu, maliyet ve bütçe planlamasına ait bilgiler sunabilir. Bu bilgilerin sözleşme bedeli arasındaki ilişki araştırılması, önemli noktalara

*Sorumlu yazarın e-posta adresi: seaslay@erzincan.edu.tr

Semi Emrah Aslay  orcid.org/0000-0002-0127-5474



vurgulanarak ihtiyaç duyulan tahmin yöntemi belirlenmesi önemlidir.

Son yıllarda birçok bilim dallarında tahmin yöntemleri araştırmalarda yer almaktadır. Bu alanda makine öğrenmesi literatürdeki popüler konulardan biridir. Metinsel dil modellerinin baskınlığı son zamanlarda sıklıkla kullanılmasına karşılık (Yazgılı ve Baykara 2022), dijital alanlardaki araştırmalar her geçen gün artmaktadır (İlgün vd. 2023). Makine öğrenmesi yöntem ve konuları diğer farklı disiplinlerde de sıklıkla kullanılmaktadır (Zeynep ve Erdal 2019). Farklı disiplinlerde yer alan bu yöntem ve konular inşaat mühendisliğinde de sıklıkla kullanılmaktadır. İnşaat mühendisliğinin tüm alt dallarında bu çalışmalarını görmek mümkündür (Thai 2022). İnşaat malzeme fiyatlarının tahmini için sinir ağı tabanlı modelin kullanılması (Mir vd. 2021), makroekonomik göstergelerle yapı malzemesi tahminin yapılması (Shiha vd. 2020), kuraklık analizleri (Başakın vd. 2019), ve konut tahmin taleplerinin tahminleri (Emeç ve Tekin 2022) örnek olarak verilebilir.

1.1. Literatür Taraması

Yapım işlerinde maliyeti temel almak suretiyle yapılan çalışmaların günden güne artmaktadır (Aslay ve Dede 2022). Çalışmalarda inşaat maliyetlerinin birçok alt kümesi olarak değerlendirilebilen kavramlar yer alır (Aslay ve Dede 2023). Bu kavramlardan biri de sözleşme bedelidir. Ancak sözleşme bedelleri ile ilgili çalışmaların daha çok maliyet odaklı olduğu söylenebilmektedir. Skitmore vd. (2003), 93 adet inşaat projesi ele alarak, sözleşme bedelini makine öğrenmesi ile tahmin etmeye çalışmıştır. Bunun için farklı modeller geliştirmiştir. Yüklenici seçim yöntemi, sözleşme düzenlemesi, proje türü gibi kriterleri kullanmıştır. Parasal tutarın yanında sözleşme türü ve inşaat süresi de analize dahil etmişlerdir. Ancak çalışmada sözleşme tutarı tahmininde elde edilen performans metrikleri oldukça düşüktür ve bu durum modelin genel tahmin yeteneğinin iyi olmadığını göstermektedir. Elhag vd. (2005) sözleşme bedeli tahmini için 67 farklı değişken üzerinde seçim yapmaya çalışmışlardır. Sözleşme bedeli aynı zamanda ihale öncesi maliyet tahmini olarak değerlendirmişlerdir. Yapılan bu çalışmada parametrelerin belirlenmesi anket yoluyla yapılmıştır ve sonuçlar tahmin modeli olarak değerlendirilmemiştir. Aziz vd. (2014) sözleşme bedeli maliyet azaltma metodları ile kullanmaya çalışmışlardır. Sözleşmede bedelinin azaltılmasından ziyade optimum değerlere ulaşmaya çalışmışlardır. Pusic vd. (2020) maliyet tahmininin inşaat sisteminin bir parçası olarak değerlendirerek, sözleşme bedelinin ön finans tahminini sinir ağı tabanlı model ile uygulamışlardır. Bunun için tarihsel veriler

ve bazı bina teknik verilerinden yararlanmışlardır. Kovacevic vd. (2021) 181 adet betonarme köprü projesi incelemişlerdir. Farklı makine öğrenmesi modellerinden yararlanmışlardır. Girdi parametreleri olarak yapısal elemanlardan faydalananak, inşaat maliyetini tahmin etmeye çalışmışlardır. Gurmu ve Miri (2023) bina maliyetini bulmak için çeşitli girdi parametreleri değerlendirmişlerdir. Bunlardan bazıları brüt zemin alanı, kullanılan malzemeler ve mimari iş kalemleridir. Farklı algoritmalar sunan çalışmada birçok parametre değeri denemiş olsa da verimlilik ölçütlerinin yeterli olmadığı söylenebilmektedir. Dang-Trinh vd. (2022), fabrika inşaat maliyeti tahmini için farklı makine öğrenmesi yöntemlerini kullandılar. Çalışma maliyet tahminleri için çeşitli tahmin metodolojilerine erişim sağlamıştır ve bir fabrikanın ön maliyetinin tahmininde en iyi modelin belirlenmesini dair çıktılar elde etmiştir. Rafiei and Adeli (2018), bina özelliklerinin yanı sıra, işçilik-malzeme endekslerini kullanarak, sinir ağları ve destek vektör makinelerine dayanan maliyet modeli geliştirdiler. Sanni-Anibire vd. (2021) yüksek binaların ön maliyeti için tahmin modelleri oluşturmuşlardır. Çalışmada makine öğrenmesi gibi modern dijital teknolojilerin inşaat endüstrisinin sorunlarını çözme potansiyeli ve tanımlanan prosedür, maliyet tahmin modellerinin geliştirilmesine katkı sunulmuştur.

İNşaat maliyetinin tahmin modeli ile ilgili geliştirilen çalışmalarda, özellikle girdi parametreleri statik veya mimari projeden elde edilen verilerle yapılmaktadır (Kovacevic vd. 2021, Gurmu ve Miri 2023). Bu durum hem uygulama süreçlerini zorlaştırmaktadır hem de zaman kaybına neden olmaktadır. Literatürdeki çalışmalarda kullanılan proje sayıları da oldukça azdır (Elhag vd. 2005, Kovacevic vd. 2021). Makine öğrenmesi modellerinde, örnek sayısı olarak net ifade söylenemez ancak veri noktalarının, tahmin modelleri üzerinde homojen bir dağılım elde edilebilmesi için örnekler analiz sonucu çıktılarda tatmin edici olmalıdır. Aynı zamanda sözleşme bedeli ile ilgili yapılan bu çalışmalarda hiper parametre optimizasyonun yapılmaması önemli bir eksiklik (Skitmore vd. 2003). Araştırmalarda sözleşme bedeli tahmini için makine öğrenmesi modellerinin daha fazla geliştirilmesi ve farklı parametrelerin çalışmalarda yer verilmesi ihtiyaç duyulmaktadır. Her ne kadar maliyet analizlerinde makine öğrenmesi yöntemleri sıklıkla kullanılsa da sözleşme bedeli olarak değerlendirilmesi ve yeni değişkenlerin ışığında modellerin geliştirilmesi önemlidir. Son araştırmalarda optimum parametrelerle öğrenme algoritma tabanlı modellerin gelişimi hızla ilerlemektedir (Takcı 2023). Kamu ihalelerinde sözleşme bedelleri tahmin yaklaşımının ihale parametrelerini kullanarak ve yeni model geliştiriciler ile

desteklenerek analizlerine yer verilmesi beklenen araştırma konularından biridir.

Bu çalışmada, yapım işleri kamu ihalelerinde, yeni yapım işlerinde, ihale parametresi olarak değerlendirilen toplam teklif sayıları, toplam geçerli teklif sayıları, doküman satın alma sayıları gibi değişkenlerle yüklenici firmalar ile kamu idareleri arasında imzalanan parasal karşılık olan sözleşme bedeli tahmin edilmeye çalışılmıştır. Bunun için 397 adet Açık İhale usulü ve Anahtar Teslim Götürü Bedel sözleşme türüne ait yapı projeleri ele alınmıştır. Makine öğrenmesi metotları uygulanmıştır. Analizlerde klasik makine öğrenmesi metotların dışına çıkılarak son zamanlarda kullanılan popüler tahmin metotları çalışılmıştır. Modeller ait parametrelerin optimizasyonlar yapılarak, her bir modele özel olarak hiper parametrik model geliştirici yöntemler denenmiştir. Hiper parametre optimizasyonları ile modellerin genel tahmin yeteneklerinin artırılması başarılı bir şekilde gerçekleştirilmiştir. Yapılan çalışmanın optimum değişken türleri ve mümkün olan model geliştirici yöntemlerle, literatüre katkı sunmaktadır.

1.2. Kamu İhaleleri ile İnşaat İşlerin Yapılması

Bu çalışmada Türkiye’de yapım işlerinde betonarme yapıların inşası ve tanzimi için harcama yetkilisi idareler tarafından gerçekleştirilen kamu ihalelerindeki verilerden yararlanılmaktadır. Kamu binaları, ilgili idarelerin ihale yapmak suretiyle gerçekleştirdiği süreçlerle mümkün olmaktadır. Bunun için 4734 ve 4735 sayılı kanunlar kullanılmaktadır. Genellikle ihale usulü olarak; açık ihale usulü, belli istekliler arasında ihale usulü ve pazarlık ihale usulü ve sözleşme türü olarak; birim fiyat, anahtar teslim götürü bedel ve karma sözleşme türleri kullanılmaktadır (Kocaman vd. 2020). Bu çalışmada kullanılan veri setlerinin tümü açık ihale usulü ve anahtar teslim götürü bedel sözleşme türüne sahip ihalelerden elde edilmiştir. Çalışmada kullanılan ihale usulü ve sözleşme türü Çizelge 1’de verilmektedir. Açık ihale usulünde ihalesi yapılacak olan yapım işinin duyurusu tüm isteklilere yapılır. Herhangi özel çağrı veya teklif yapılmaz. İnşaat işi ile ilgili gerekli şartlara sahip olan herhangi bir yüklenici firma, ilgili harcama yetkilisinin belirttiği koşullara uygun

şekilde teklif verebilir. Teklifler ihale şartnamesinde belirtilir ve işin durumuna bağlı olarak uygun standartlarda değerlendirilerek sonuçlanır. Sözleşme türü olan ve çalışmada da kullanılan anahtar teslim götürü bedel sıklıkla ihalelerde tercih edilir. Bu ifade, yüklenici inşaat firmalarının taahhüt etmiş oldukları parasal bedel karşılığında, bir inşaat projesinin baştan sona tüm aşamaları ile insanların kullanımına hazır olacak şekilde tamamlanmasını belirtir. Bunun için söz konusu iş, işverene teslim edilir ve ilgili idare fen-sanat noktasından belirli aralıklarla kontrolleri yapar. Bu tür ihalelerde proje bütçesi değişmez veya çok az değişir ve tüm riskleri müteahhit firma üstlenir. İnşaat işi anlaşmaya varılan gün ve sözleşme bedeli ile tamamlanır.

2. Gereç ve Yöntem

2.1. Veri Setinin Tanımı

Bu çalışmada Türkiye’de kamu ihalelerinde ihalesi yapılmış olan 397 adet, yeni yapım işlerinden oluşan ve betonarme yapılardan alınan veriler kullanılmıştır. Bu veriler elektronik kamu alım platformundan ‘ekap’ elde edilmiştir. Bunun için konusunda uzman inşaat mühendis tarafından gerekli inşaat taban alanı hesabı ve ihale parametre bilgilerine ait okumalar yapılmıştır. Projeler sadece yeni yapım işlerini kapsamaktadır, tadilat işleri, onarım-güçlendirme işleri yer almamaktadır. Projelerin tamamı temelden başlamak üzere, inşaata ait tüm imalatların sonlandırılmasını kapsamaktadır. Aynı zamanda bu durum Kamu İhale Mevzuatında ‘Anahtar teslim götürü bedel’ olarak adlandırılan ihale yöntemi ile yapımı tamamlanan işleri kapsamaktadır. Yapıların tamamı betonarme olarak inşa edilmiştir. Farklı kat sayıları ve farklı kullanım amacı olan bina verilerinden yararlanılmıştır. Çalışma kapsamında oluşturulan modelde 5 farklı bağımsız değişken ve 1 adet bağımlı değişken yer almaktadır. Toplam 6 adet olan özniteliklerin açıklamaları Çizelge 2’de verilmektedir.

Bağımsız değişkenler seçilirken temel amaçlardan biri statik proje değişkenleri (Kovacevic vd. 2021) ve mimari projelerdeki değişken (Gurmu ve Miri 2023) bilgileri tam olarak bilinmeden ihale aşamasında sözleşme bedeli hakkında tahmin modeli oluşturmaktır. Çalışmanın özgün yanlarından

Çizelge 1. İhale Usulleri ve Sözleşme Türleri (4734 Sayılı Kamu İhale Kanunu).

İhale Usulleri	Sözleşme Türleri	Bu Çalışmada Kullanılan Sözleşme Türleri ve İhale Usulleri
* Açık ihale usulü * Belli istekliler arasında ihale usulü * Pazarlık ihale usulü	* Anahtar Teslim Götürü bedel * Birim fiyat * Karma	* Açık ihale usulü * Anahtar Teslim Götürü bedel

Çizelge 2. Özniteliklere ait açıklamalar (4734, Sayılı Kamu İhale Kanunu).

Tanım	Değişken Türü	Açıklama	Kısaltma
Sözleşme Bedeli	Bağımlı Değ.	Yüklenici firma ile işin idaresi arasında anlaşmaya varılan parasal tutar	sb
Doküman Satın Alan Sayısı	Bağımsız Değ.	İsteklilerin işin idaresine gelerek para karşılığı yapım işi hakkında belge olarak aldığı doküman sayısı	dsas
Dokümanı EKAP üzerinden e-imza kullanarak indiren sayısı	Bağımsız Değ.	İsteklilerin internet üzerinden talep ettikleri ihale dokümanı sayısı	deis
Toplam Teklif Sayısı	Bağımsız Değ.	İsteklilerin yapım işini taahhüt ettikleri parasal karşılık ile yapacaklarına dair verdikleri beyan sayısı	tts
Toplam Geçerli Teklif Sayısı	Bağımsız Değ.	İsteklilerin taahhüt etmiş oldukları beyanlarından herhangi eksiklik olmaksızın idarenin yapabilir onayı verme sayısı	tgts
İnşaat Taban Alanı	Bağımsız Değ.	İlgili yapım işine ait binanın sahip olduğu taban alanı. M2 olarak değerlendirmeye alınmıştır.	tabal

bir tanesi de budur. Bunun için sözleşme bedeli ile ilişkili olan ve analizlerde olumlu sonuçlar veren, satın alan sayıları, isteklilerin internet üzerinden talep ettikleri ihale doküman sayıları, toplam teklif sayıları, geçerli teklif sayıları girdi parametreleri kullanılmıştır. Bununla birlikte mevcut girdileri destekleyen ve bina karakteristiğini yansıtan inşaat taban alanı kullanılmıştır. Bu alan, maliyet tahmininde regresyon analizi gibi istatistiksel modellerde yaygın olarak kullanılan bir değişkendir ve maliyet ile doğrudan ilişkisi bulunur (Ali ve Burhan 2023, Wang vd. 2022). Aynı zamanda hedef verisi olarak da adlandırılan bağımsız değişken ise sözleşme bedelidir. Sözleşme bedeli müteahhit firmaların herhangi bir iş için ilgili idareye verdikleri taahhüt bedelini ve bu bedelle karşılık da harcama yetkilisinin onayını ifade eder. Harcama yetkilisi ihale isteklileri arasından en avantajlı teklifi değerlendirerek uygun gördüğü fiyat üzerinden yüklenici ile anlaşır. Bu anlaşma koşul ve detayları 4734 ve 4735 sayılı kanunlarda yer almaktadır. Veri setlerinde bağımlı öz-nitelik olarak teklif sayıları ve bina karakteristik özellikleri değerlendirilmektedir. Teklif sayıları kendi aralarında farklı kategoriler içermektedir. İhale büyüklüğü veya avantaj durumunu göre bu kategoriler farklı anlamlar ifade etmektedir. Hem korelasyon matrislerinde hem de veri analizlerinde bu durum detaylı olarak değerlendirilmiştir.

2.2. Makine Öğrenmesi Yöntemleri

2.2.1. Gradyan Artırıcı Karar Ağacı (Extreme Gradient Boosting)

Literatürde 'XGBoost' olarak adlandırılan yöntem, karar ağacı temellidir. Topluluk öğrenme prensibine dayanır ve parametrelere farklı ağırlıklar vererek tahminlerde bulunur.

Veri setlerine ait değişkenlerdeki ağırlıklar ağaç topluluğu büyüdükçe güncellenir (Ay ve Ekinci 2022). Bu yöntem gradyan artırma makinesi algoritmasını daha hızlı yapmak için geliştirilmiştir. Bunun için bir modelin eğitim verisi üzerinde çok iyi performans göstermesine rağmen, yeni veriler üzerinde yetersiz performans sergilemesi olan aşırı öğrenmeyi azaltmak ve eğitim hızını arttırmak için rasgele örnek alma tekniği kullanır. Aynı zamanda sütun tabanlı bir yapısı vardır ve büyük veri kümelerinde doğru sonuca ulaşır. Tüm bu nedenlerden dolayı son dönemler sıklıkla kullanılan popüler bir algoritmadır (Thai 2022). Bu yöntemle ait denklem eşitlik 1'de verilmektedir. Buradaki amaç daha küçük parçalarla başarının daha fazla arttırılmasıdır. Bu denkleme göre, $\sum_{i=1}^n$ i indisine bağlı olarak 1'den 'n' kadar toplamı, $L(x_i, y_i)$ modelin verimliliğini ve hatasını ölçen fonksiyondur, $\frac{1}{2}\alpha$ modele ait düzenleme parametresidir, O^2v modelin ikinci derece türevini temsil eder.

$$\sum_{i=1}^n L(x_i, y_i) + \frac{1}{2}\alpha O^2v \quad (1)$$

2.2.2. Yapay Sinir Ağları (Artificial Neural Network)

İnsan beyninden esinlenerek oluşturulan model, makine öğrenmesi yöntemlerinde sıklıkla başvurulmaktadır. Temelinde katmanlar ve ağırlıklandırılmalar bulunur (Emeç ve Tekin 2022). Katmanlar genellikle 3 tiptedir. Her katman birbirlerine nöronlarla bağlıdır. Nöronların girişlerinde ağırlıklandırılmalar bulunur ve işleyişi etkileyen ana unsurdur. Ağırlıklandırılmalar, öğrenme, genelleme, hesaplama maliyeti ve performans doğrulukları ile belirlenir. Bu şekilde modelin genelleme yeteneği performans kabiliyeti problem üzerinde önemli bir rol oynar. Yöntemde kullanılan girdi ve

çıktı nöronlarının nasıl işleyeceğini gösteren matematiksel ifade aynı zamanda temel fonksiyondur (Eşitlik 2). Burada 'y' nöronun çıktısı, 'f' aktivasyon fonksiyonu, 'n' girdi sayısı, "i. Girdinin ağırlık değeri, "i. Girdi ve 'b' bias terimidir (Li, Zhang ve Liu 2017).

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (2)$$

2.2.3. Destek Vektör Makinesi (Support Vektor Machine)

Bağımsız değişkenlerin sayısı kadar boyutu olan bir uzayda, en uygun hiper düzlem oluşturulmaya çalışılır. Hiper düzlem herhangi bir x-y doğrusunda verileri bağlı oluşturulan paralel çizgilerdir (Sinap 2023). Bu çizgiler en iyi tahminin yapılması amacıyla geniş tutulmaya çalışılır. Bunlar aynı zamanda karar sınırları olarak da adlandırılırlar. Karar sınırları olarak belirlenen alan veri gruplarında tahminlerin en iyi şekilde temsil edilmesi beklenir. Gerçek değerler ile tahmin değerler ilişki için genel bir çözüm sunar (Şahin vd. 2023). Yönteme ait denklem eşitlik 3'te verilmektedir. Burada çekirdek parametreleri olarak γ , r ve d kullanılmıştır ve fonksiyon radyal tabanlıdır. Denklemde, $K(x_i, y_i)$ kernel (çekirdek) fonksiyonudur, \exp üstel fonksiyondur, $-\gamma$ üstel fonksiyonun içerisinde yer alan negatif bir katsayıyı ifade eder, $\|x_i, y_i\|^2$ x ve y arasındaki öklid mesafenin karesini ifade eder.

$$K(x_i, y_i) = \exp(-\gamma \|x_i, y_i\|^2) \quad \gamma > 0 \quad (3)$$

2.2.4 Bayes Regresyonu (Bayesian Regression)

Bayes yaklaşımı veri analizlerinde olasılıksal dağılım kullanılır. Veri setlerindeki uyumsuzlukları, başlangıç tahmini ve veriye dayalı olasılık fonksiyonu kullanarak gidermeye çalışır. Geleneksel makine öğrenimi yöntemlerinin aksine, nokta tahminlerine odaklanmak yerine, model parametreleri ve tahminler üzerinde olasılık dağılımlarını içerir ve bu da belirsizliğin daha kapsamlı çözümünü ortaya çıkarır (Bhargava 2023). Yönteme ait örneğin deneme ile elde edilen olasılığını hesaplayan denklem eşitlik 4'te verilmektedir. Burada, "bağımlı değişken, 'X' bağımsız değişkenler matrisini, 'β' ağırlıklar matrisi ve biası temsil etmektedir (Özçift vd. 2019).

$$P(y = 1 | X, \beta) = \frac{1}{1 + \exp(-X \beta)} \quad (4)$$

2.2.5 K-En Yakın Komşu (K-Nearest Neighbour)

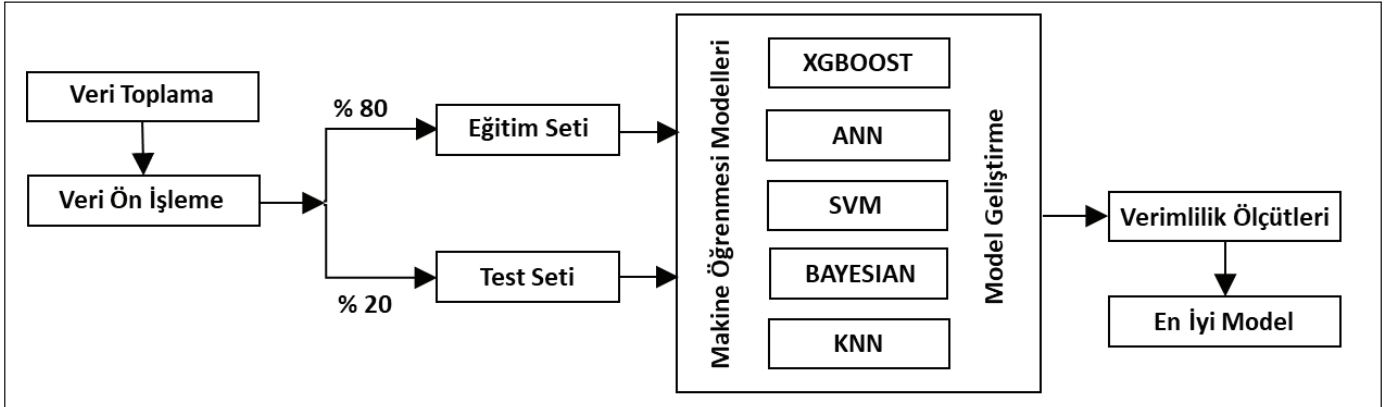
Bu yöntem uygulama kolaylığı ve işlem süresinin az olması nedeniyle araştırmalarda sıklıkla kullanılmaktadır. Parametrik olmayan bir modeldir. 'K' harfi komşu sayısını ifade eder ve verilerin oluşturduğu kümelerin adetidir. Eğitim kümesi içerisinde k adet oluşan sınıfların ortalaması 'K' sayısı ile

hesaplanır. Mesafe fonksiyonu oluşturularak, bağımsız değişkenlerin yakınlıkları ve tahmin değerlerinin ortalaması alınarak en iyi sonuca ulaşılmaya çalışılır (Başakın vd. 2019, Sonuç ve Özcan 2022). KNN yöntemi temel olarak metrik mesafe değerine dayanır ve eşitlik 5 'de verilmektedir.

$$d(x, y) = \sqrt{\sum_{i=1}^n \sqrt{(y_i - x_i)^2}} \quad (5)$$

2.3. Tahmin Modelinin Oluşturulması

Bu çalışmada 5 farklı makine öğrenmesi algoritmasından yararlanılmaktadır. Bunlar; gradyan Artırıcı karar ağacı (XGBoost), yapay sinir ağları (ANN), destek vektör makinesi (SVM), bayes regresyonu (Bayesian Regression), K-en yakın komşu (KNN) algoritmalarıdır. Kullanılan algoritmalar farklı avantajlar sunarak çeşitli veri setleri ve problemler için etkili çözümler sağlar. XGBoost, yüksek doğruluk oranı elde eder, karmaşık problemlerde etkilidir ve esneklik sunar. ANN karmaşık desenleri öğrenme yeteneği iyidir büyük verilerde etkili çözüm sunar. SVM, kategorik özelliğe sahiptir ve yüksek boyutlu veri setlerinde margin farkını maksimize eder. Bayes regresyonu, güven aralıklarını hesaplar ve veri setlerindeki belirsizliği yönetebilir. KNN temel bir öğrenim algoritmasıdır, yöntem olarak mesafeleri kullanarak hızlı ve etkili tahminlerde bulunur. Bu algoritmaların kullanımı, veri setinin özelliklerine ve problem gereksinimlerine bağlı olarak model performansını karşılaştırarak en uygun çözümün seçimine olanak tanır. Bu algoritmalar seçilirken tüm bu özellikleri ve veri setlerinin yapısı, problem türü göz önüne alınmıştır. Eğitimi ve test verileri için kaynak havuzundan alınan örneklerde %50-%50, %60-%40, %70-%30 ve %80-%20 oranlarının tümü değerlendirilerek analiz yapılmıştır. Tüm karşılaştırmalı analiz sonuçların içerisinde eğitim-test verisi olarak en iyi sonuç veren oranı %80-%20'dir. Bu nedenle, literatürde de kullanılabilen (Kilinc, Haznedar, Ozkan ve Katipoğlu, 2024) %80-%20 oranı bu çalışmada da kullanılmıştır. Hazırlanan veriler eğitim ve test verileri %80-%20 olarak bölünmüştür. Veri ön işleme adımları standart olarak kontrol edilmiştir. Veri setindeki değerleri belirli bir standart formata dönüştürme işlemi olan standardizasyon işlemleri gerçekleştirilmiştir. Veri setindeki değerlerin belirli bir ortalamaya ve varyansa sahip olmasını sağlanmıştır, böylece farklı özellikler arasındaki ölçek farklılıkları giderilerek işlemlere devam edilmiştir. Analiz işlemleri yapılarak etkinlik metrikleri ayrı ayrı incelenmiştir. Etkinlik değerlerinin artırılabilmesi için çapraz doğrulama sayısını değiştirilerek farklı kombinasyonlar elde edilmiştir. Çapraz doğrulama işlemi makine öğrenimi ve istatistiksel işlemlerde doğrulama tekniklerindedir. K-katman veya araştırmalardaki bilinen



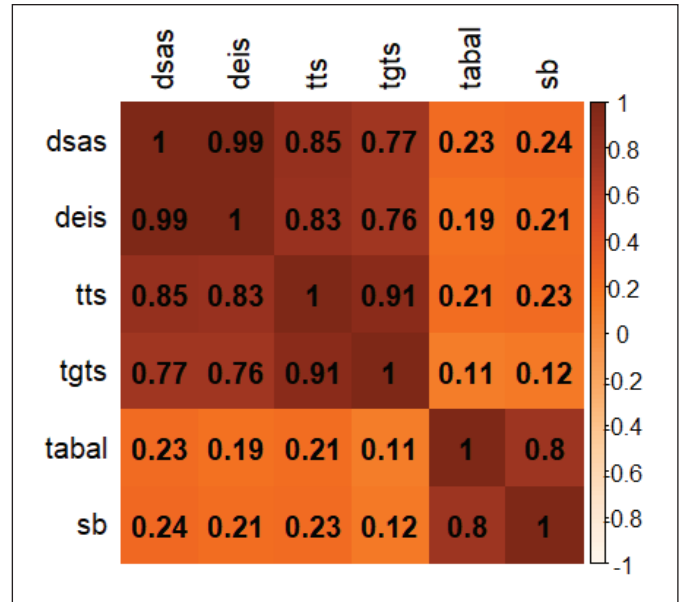
Şekil 1. İş akış diyagramı.

diğer adıyla K-fold değeri veri kümesini alt kümlere ayırarak farklı ihtimalleri kullanıcı sunmaktadır. Bu çalışmada k-katman değeri 5-10 arasında denemiştir. En iyi sonucu 5 katmana bölünmesi ile elde edilmiştir. Hiper parametre optimizasyon işlemi çalışmada başvuru diğer aşamadır. Bu süreçte modele ait algoritmaların parametre değerleri, model verimliliğini arttırmak için optimize edilir. Bu çalışmada artırıcı karar ağacı ve yapay sinir ağlarında model performansına katkıda bulunduğu söylenebilmektedir. Değerlendirme ölçütü olarak, ortalama mutlak hata (MAE), karekök ortalama kare hatası (RMSE) ve R-kare (R^2) metrikleri kullanılarak karşılaştırılmıştır. En verimli modeller bu metrikler üzerinden değerlendirilmiştir. Çalışma aşamalarına ait iş akış diyagramı Şekil 1'de verilmektedir.

3. Bulgular

Bu çalışmada 5 farklı öznelikten yararlanılmıştır. Bunlar özellikle ihale istekli teklifleri ve inşaat özelliklerini barındırmaktadır. Bunlar doküman satın alan sayıları, isteklilerin internet üzerinden talep ettikleri ihale doküman sayıları, toplam teklif sayıları, geçerli teklif sayıları ve inşaat taban alanları olarak belirlenmiştir. Değişkenlerin etki değerleri göz önünde bulundurulmuştur. Bu özelliklerin hem kendi aralarında hem de hedef öznelilik arasındaki ilişkileri korelasyon matrisi ile anlamlandırılmıştır. Şekil 2'de değişkenlere ait ilişki sayıları verilmektedir. Buna göre inşaatın taban alanının sahip olduğu etki puanı fazla olmasına karşılık, diğer değişkenlerde anlamlı değerlere sahiptir. Ayrıca öznelikler ayrı ayrı analize dahil edilmiştir. Etki puanı fazla olan değişkenler ayrı analizlerle birlikte değerlendirildiğinde tek başına olmasından ziyade birlikte değerlendirilerek daha performanslı metriklerin elde edildiği görülmektedir.

Bu çalışmada gradyan artırıcı karar ağacı, yapay sinir ağları, destek vektör makinesi, bayes regresyonu, K-en yakın komşu



Şekil 2. Korelasyon matrisi.

algoritmaları ile veri analizleri gerçekleştirilmektedir. Bu algoritmalara ait etkinlik kriterleri Çizelge 3'te verilmektedir. Buna göre en iyi sonuçlar R-kare değeri 0,9435 olan gradyan artırıcı karar ağacından ve R-kare değeri 0,9215 olan yapay sinir ağlarından elde edilmektedir. Bu 2 modelin yine metrikleri olan ortalama mutlak hata ve karekök ortalama kare hatası uyumlu seviyelerdedir. Destek vektör makinesi ve bayes regresyonu verimlilik ölçütleri her ne kadar 3. ve 4. sırada bulunsada elde edilen metriklerin tümüne bakıldığında kabul edilebilir seviyelerde olduğu söylenebilmektedir. Etkinlik seviyesinde en alta yer alan K-en yakın komşu yönteminin R-kare değeri 0,7768 olarak elde edilmiştir. Bu sonuçla verimlilik değeri olumsuz algoritma olarak test edilmiştir. Şekil 3'te kullanılan yöntemlerin saçılım grafikleri verilmektedir. Buna göre modellere ait gerçek değerler ve

Çizelge 3. Makine öğrenmesi modellerine ait performans metriklerinin karşılaştırılması.

Method	R ²	MAE	RMSE
Gradyan artırıcı karar ağacı (XGBOOST)	0.9435	1.2988	2.0621
Yapay sinir ağları (ANN)	0.9215	1.3939	2.5762
Destek vektör makinesi (SVM)	0.8735	1.6265	5.3335
Bayes regresyonu (BAYESIAN REG)	0.8632	1.8288	4.6595
K-en yakın komşu (KNN)	0.7768	2.0097	6.0291

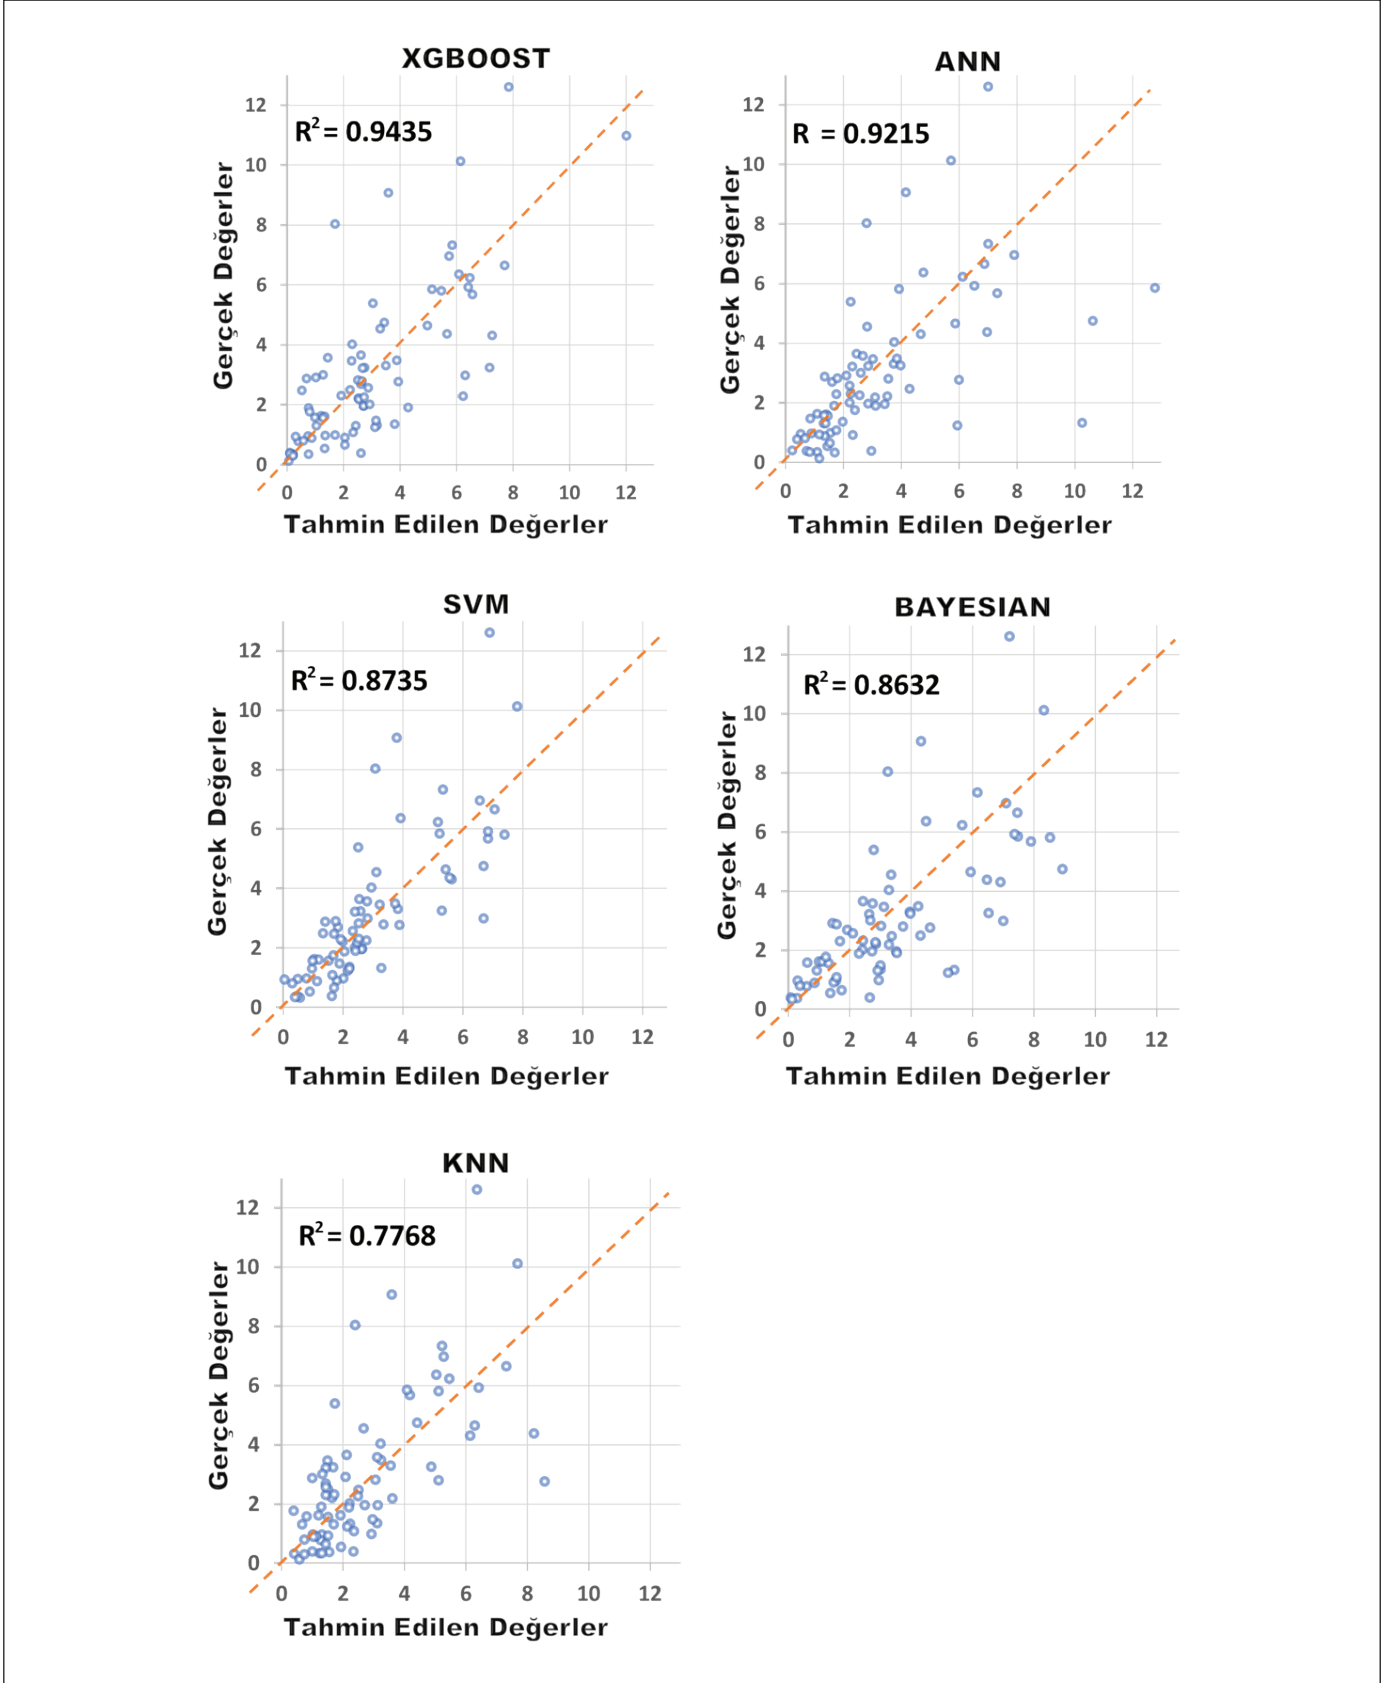
tahmini değerler arasındaki ilişki kolayca anlaşılabilir. Veri nokta dağılımları olarak bakılabilen grafiklerde, bu dağılımların XGBoost'da ve ANN'de diğer modellere göre daha homojen olduğu görülmektedir. Ancak diğer modellerde de noktasal dağılımın çok kötü olduğu söylenemez. Tüm grafiklerde rasgele dağılmış olan verilerin varlığı olsa da belirli bir desen görünümü vardır ve görünüm kabul edilebilir seviyededir. Araştırmada kullanılan yapım işleri ihalelerindeki parametrelerin kullanıldığı çalışmalara literatürde pek rastlanmadığı söylenebilmektedir. İnşaat maliyetleri ile ilgili makine öğrenmesi araştırmalar bulunmakla birlikte veri setlerine ve değişken tiplerini göre performans metrikleri çok farklılık göstermektedir. Bununla birlikte regresyon analizlerinde R-kare değeri veri analizlerinde sıklıkla başvurulan sayısal ifadelerdir. Bu çalışmada bina özelliği olarak sadece taban inşaat alanı kullanılmaktadır. Bu parametre ihale teklif verileri ile uyumlu olduğu gözlenmiştir. Aynı zamanda parametreler birbirinin performanslarını artırıcı rol oynamıştır. Bunun için farklı veri analizleri kullanılmıştır. Çalışmada model etkinliği arttırmaya yönelik olarak hiper parametre optimizasyonu kullanılmıştır. Yapılan parametre optimizasyonu ile özellikle gradyan artırıcı karar ağacı ve yapay sinir ağları yöntemlerinde başarılı sonuçlar elde edilmiştir. Tüm veri ön işleme ve model geliştirme bölümleri rutin bir şekilde denenerek mümkün olan en iyi sonuçlarında elde edilmesinden sonra yapılan hiper parametre optimizasyonu modelin performans metriklerini arttırmıştır. Yapılan optimizasyon işlemi ile algoritmaların farklı kombinasyon seçenekleri hızlı bir şekilde denenmiştir ve mümkün olan en iyi sonuçlara ulaşılmaya çalışılmıştır. Yönetilen tüm süreçlerle modelin daha iyi bir genelleme yapılması sağlanmıştır.

4. Tartışma

İnşaat projelerinin maliyetine yönelik çalışmalarda girdi parametreleri çok farklılık gösterebilmektedir. Kamu ihalelerinde yüklenici firmalar için inşaat maliyetlerinin karşılığı olarak, sözleşme bedelinin hızlı bir şekilde tahmin edilmesi

önemlidir. İnşaat maliyetine yönelik olarak yapılan birçok çalışmada farklı mimari (Gurmu ve Miri 2023), statik (Kovacevic vd. 2021) veya projeye özgü parametreleri (Skitmore vd. 2003), kullandıkları söylenebilir.

Rafiei and Adeli (2018), inşaat-arsa alanları, inşaat süresi, işçilik-malzeme endekslerini, Dang-Trinh vd. (2022), bina katsayıları, kolon aks mesafelerini, duvar -çatı tiplerini, Gurmu and Miri (2023), bina tipleri, çatı-duvar-çerçeve malzeme özelliklerini girdi parametreleri olarak kullanmışlardır. Bu çalışmada ise kamu ihalelerindeki proje parametreleri kullanılmıştır. Bu parametrelere bina karakteristik özelliklerinden sadece 1 tanesi eklenmiştir. Girdi parametrelerinin ihaleye ait verilerden seçilme nedeni ise, yüklenici firmaların ve ilgili idarelerin projedeki verileri tam olarak bilmeden dahi sözleşme bedeli için bir hızlı öngörü kazanmalarını sağlamaktır. Literatürdeki benzer çalışmalarda Skitmore vd. (2003) 93 adet inşaat projesi, Kovacevic vd. (2021) 181 adet betonarme köprü projesinden faydalanmıştır. Mevcut proje sayılarının makine öğrenmesi yöntemleri için fazla olduğu söylenemez, zira bu veri adeti grafiksel yorumlarda yeterli seviyede olamamaktadır. Özellikle saçılım grafiklerinde verilerin homojen dağılımına bakabilmek için fazla veriye ihtiyaç vardır. Bu çalışmada 397 adet veri kullanılmıştır. Grafik ve tabloların yorumlanması diğer çalışmalara göre daha net ifade edilmiştir. Aynı zamanda ihale parametrelerinin kullanılması daha fazla projeden hızlı veri elde etme imkanı sunmuştur. Literatürdeki çalışmaların performans metriklerine bakıldığında yönteminin R-kare değerlerinin çok iyi olmadığı görülmektedir. Gurmu and Miri (2023) ve Skitmore vd. (2003) R-kare değerleri 0,50-0,66 arasında değişirken, Kovacevic vd. (2021) 0,89, Dang-Trinh vd. (2022) 0,91, Sanni-Anibire vd. (2021) 0,81 olarak elde etmiştir. Bu çalışmada en iyi R-kare değeri 0,94 olarak elde edilmiştir. Bu araştırma girdi parametrelerinin zenginliği, proje sayısı, kullandığı yöntemler ve elde ettiği başarılı verimlilik ölçüt sonuçlarıyla sözleşme bedeli tahmini konusunda literatüre katkı sunmaktadır.



Şekil 3. Saçılım grafiği.

5. Sonuç ve Öneriler

Bu çalışmada yapım işlerinde kamu ihalelerinde, yüklenici firmalara ait farklı teklif parametreleri kullanılarak, makine öğrenmesi yöntemi ile sözleşme bedeli tahmini yapılmaya çalışılmıştır. Bunun için elektronik kamu alım platformundan, 397 adet yapı projelerine ait veriler toplanmıştır. Bu verilerden bağımsız değişkenler olarak; müteahhit firmaların ilgili projeleri anahtar teslim götürü bedel olarak yapmayı planlayarak verdikleri toplam teklif sayıları, toplam geçerli teklif sayıları, doküman satın alma sayıları ve dokümanı e-imza ile indirme sayılarını kapsamaktadır. Ayrıca bina karakteristiği için yapı taban alanları da bağımsız değişkenlere dahil edilerek, netice de yüklenici firma ile işin idaresi arasında anlaşmaya varılan parasal tutar, yani sözleşme bedeli tahmin edilmeye amaçlanmıştır. Esasen ihale parametrelerinin sözleşme bedeli tahmini olan katkısı ve ilişkisi yapay zekâ alt dallarından olan makine öğrenmesi ile gerçekleştirilmiştir.

Makine öğrenmesi algoritmalarında farklı seçenekler çalışmada değerlendirilmiştir ve 5 farklı algoritmanın veri setleri için uyumlu olduğuna karar verilmiştir. Bunlar; gradyan artırıcı karar ağacı (XGBoost), yapay sinir ağları (ANN), destek vektör makinesi (SVM), bayes regresyonu (BAYESIAN REG), K-en yakın komşu (KNN) algoritmalarıdır. Bunlar hem temel algoritmalar hem de son yıllarda literatürde sıklıkla kullanılan algoritmalarıdır.

Makine öğrenmesi yöntemlerindeki aşamalar özenle değerlendirilmiştir. Veri ön işleme aşamaları makale içinde detaylı olarak anlatılmıştır ve modellerin genelleme yeteneğine katkıda bulunmuştur. Model geliştirme teknikleri de her aşamada analize dahil edilmiştir. Veri analizlerinde hiper parametre optimizasyonu da uygulanmıştır. Özellikle gradyan artırıcı karar ağacı ve yapay sinir ağlarında hiper parametre optimizasyonu model tahminine katkıda bulunarak performans metriklerinde değerlendirilmiştir. Tüm algoritmalar göz önüne alındığında hem metriklerde hem saçılım grafiklerinin uyumlu ve kabul edilebilir seviyelerde olmasına karşılık, K-en yakın komşu algoritması en zayıf tahmin değerini elde etmiştir. Bundan sonra, bayes regresyonu ve destek vektör makinesi bu veri setlerinde daha iyi sonuç vermiştir. En iyi sonuçlar R-kare değerleri 0,90 üzerinde olan gradyan artırıcı karar ağacı ve yapay sinir ağlarından elde edilmiştir. Gradyan artırıcı karar ağacı (XGBoost), 0,9435 R-kare katsayısı ve 2,0621 karekök ortalama kare hatası ile en gerçekçi sonuçları vermiştir. Buna göre makine öğrenmesi algoritmalarından başarılı sonuçlar elde edilerek uygun genellemelerde bulunulmuştur. Kamu ihalelerinde inşaat

karakteristiği ile ihale parametrelerinin yüklenicilerin taahhüt ettiği değer üzerinde anlamlı ilişkisi vardır. Bununla birlikte ihale isteklilerin hem gerçek teklifleri hem de projeleri değerlendirmek için dokümana olan talep ve yoğunlukları inşaatın parasal değeri üzerindeki etkisi anlamlandırılmıştır. Bu çalışma ile proje verilerine ihtiyaç olmaksızın ihale parametreleri kullanılarak, ilgili idare ve yüklenici firma için hızlı öngörülebilir bir maliyet sunmaktadır. İhaleyi yapan idareler elde ettikleri maliyet tahminiyle ihale sonucunda yapılabilecek herhangi bir teknik-parasal hatanın veya olağandışı sözleşme bedelinin fark edilmesi durumunda, yükleniciler ise ihale sonucunda yapılabilecek herhangi bir hatanın veya olağandışı fiyatların fark edilmesi, kar analizinin yapılması, hızlı finansal değerlendirme sonucunda aksi bir durumla karşılaşılması halinde, her iki taraf da itiraz süreçlerinin veya hukuksal başvuruların zamanında başlatılabileceklerdir. Bu çalışma İdare ve yüklenici arasında parasal problemlerin yaşanmaması ve yapım ihalelerinin uygulama süreçlerindeki hata-aksaklıkların oluşmaması için çözüm sunmaktadır.

Gelecekteki çalışmalarda, bu çalışmanın kısıtları olarak da değerlendirilebilecek noktalar arasında, performans metriklerinin geliştirilmesi, veri setinin genişletilmesi ve açıklanabilir makine öğrenmesi yöntemlerinin uygulanması yer almaktadır.

6. Kaynaklar

4734 Sayılı Kamu İhale Kanunu. (t.y.).

Ali, ZH., Burhan, AM. 2023. Hybrid machine learning approach for construction cost estimation: an evaluation of extreme gradient boosting model. *Asian Journal of Civil Engineering*, 24(7): 2427-2442. doi:10.1007/s42107-023-00651-z

Aslay, SE., Dede, T. 2022. 3D cost optimization of 3 story RC constructional building using Jaya algorithm. *Structures*, 40: 803-811. doi:10.1016/j.jstruc.2022.04.055

Aslay, SE., Dede, T. 2023. Reduce the construction cost of a 7-story RC public building with metaheuristic algorithms. *Architectural Engineering and Design Management*, doi:10.1080/17452007.2023.2195612

Ay, Ş., Ekinci, E. 2022. Comparison of Machine Learning and Deep Learning Methods for Modeling Ozone Concentrations. *Journal of Intelligent Systems: Theory and Applications*, 5(2): 106-118. doi:10.38016/jista.1054331

Aziz, RF., Hafez, SM., Abuel-Magd, YR. 2014. Smart optimization for mega construction projects using artificial intelligence. *Alexandria Engineering Journal*, 53(3): 591-606. doi:10.1016/j.aej.2014.05.003

Başakın, EE., Ekmekcioğlu, Ö., Ozger, M. 2019. Drought Analysis with Machine Learning Methods. *Pamukkale University Journal of Engineering Sciences*, 25(8): 985-991. doi:10.5505/pajes.2019.34392

- Bharadiya, JP. 2023.** A Review of Bayesian Machine Learning Principles, Methods, and Applications. *International Journal of Innovative Science and Research Technology (C. 8)*. www.ijisrt.com adresinden erişildi.
- Car-Pusic, D., Petruseva, S., Zileska Pancovska, V., Zafirovski, Z. 2020.** Neural Network-Based Model for Predicting Preliminary Construction Cost as Part of Cost Predicting System. *Advances in Civil Engineering*. doi:10.1155/2020/8886170
- Dang-Trinh, N., Duc-Thang, P., Nguyen-Ngoc Cuong, T., Duc-Hoc, T. 2022.** Machine learning models for estimating preliminary factory construction cost: case study in Southern Vietnam. *International Journal of Construction Management*, doi:10.1080/15623599.2022.2106043
- Elhag, TMS., Boussabaine, AH., Ballal, TMA. 2005.** Critical determinants of construction tendering costs: Quantity surveyors' standpoint. *International Journal of Project Management*, 23(7): 538-545. doi:10.1016/j.ijproman.2005.04.002
- Emeç, Ş., Tekin, D. 2022.** Housing Demand Forecasting with Machine Learning Methods. *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(Special Issue I): 36-52. doi:10.18185/erzifbed.1199535
- Gurmu, A., Miri, MP. 2023.** Machine learning regression for estimating the cost range of building projects. *Construction Innovation*. doi:10.1108/CI-08-2022-0197
- İlgün, EG., Sönmez, Y., Dener, M. 2023.** Makine Öğrenme Yöntemi Kullanılarak DarkWEB Trafik Tespiti ve Sınıflandırılması. *Gazi Journal of Engineering Sciences*, 9(4): 126-140. doi:10.30855/gmbd.0705s13
- Kilinc, HC., Haznedar, B., Ozkan, F., Katipoğlu, OM. 2024.** An evolutionary hybrid method based on particle swarm optimization algorithm and extreme gradient boosting for short-term streamflow forecasting. *Acta Geophysica*. doi:10.1007/s11600-024-01307-5
- Kocaman, E., Kuru, M., Çaliş, G. 2020.** Investigating the effect of tendering procedure and contract type on the construction contract price. *Teknik Dergi/Technical Journal of Turkish Chamber of Civil Engineers*, 31(1): 9789-9812. doi:10.18400/TEKDERG.458054
- Kovacevic, M., Ivanišević, N., Petronijević, P., Despotovic, V. 2021.** Construction cost estimation of reinforced and pre-stressed concrete bridges using machine learning. *Gradjevinar*, 73(1): 1-13. doi:10.14256/JCE.2738.2019
- Li, H., Zhang, Z., Liu, Z. 2017.** Application of artificial neural networks for catalysis: A review. *Catalysts*. MDPI. doi:10.3390/catal7100306
- Mir, M., Kabir, HM. D., Nasirzadeh, F., Khosravi, A. 2021.** Neural network-based interval forecasting of construction material prices. *Journal of Building Engineering*, 39. doi:10.1016/j.jobe.2021.102288
- Özçift, A., Kılınç, D., Bozyiğit, F. 2019.** Grid Aramayla Optimize Edilmiş Bayes Lojistik Regresyon Algoritmasının Türkçe Mikro Blog Verilerinde Sanal Zorbalık Tespitinde Kullanılması. *Academic Platform Journal of Engineering and Science*, 7(3): 355-361. doi:10.21541/apjes.496018
- Rafiei, MH., Adeli, H. 2018.** Novel Machine-Learning Model for Estimating Construction Costs Considering Economic Variables and Indexes. *Journal of Construction Engineering and Management*, 144(12). doi:10.1061/(asce)co.1943-7862.0001570
- Sanni-Anibire, MO., Mohamad Zin, R., Olatunji, SO. 2021.** Developing a preliminary cost estimation model for tall buildings based on machine learning. *International Journal of Management Science and Engineering Management*, 16(2): 134-142. doi:10.1080/17509653.2021.1905568
- Shiha, A., Dorra, EM., Nassar, K. 2020.** Neural Networks Model for Prediction of Construction Material Prices in Egypt Using Macroeconomic Indicators. *Journal of Construction Engineering and Management*, 146(3). doi:10.1061/(asce)co.1943-7862.0001785
- Sinap, V. 2023.** Makine Öğrenmesi Teknikleri ile Counter-Strike: Global Offensive Raunt Sonuçlarının Tahminlenmesi. *Journal of Intelligent Systems: Theory and Applications*, 6(2): 119-129. doi:10.38016/jista.1235031
- Skitmore, RM., Ng, ST., Ng, T. 2003.** Building and Environment Forecast Models for Actual Construction Time and Cost. *Building and Environment*, 38(8): 1075-1083.
- Sonuç, E., Özcan, E. 2022.** Makine Öğrenme Teknikleri Kullanılarak Kükürt Giderme İşleminde Kullanılan Malzeme Miktarının Tahmini. *Journal of Intelligent Systems: Theory and Applications*, 5(1): 57-63. doi:10.38016/jista.993853
- Şahin, F., Tulum, G., Karaca, Ş. 2023.** Anne Sağlığı Riski İçin Makine Öğrenmesi Modellerinin Performans Karşılaştırması. *DÜMF Mühendislik Dergisi*. doi:10.24012/dumf.1325431
- Takcı, H. 2023.** Performance-enhanced KNN algorithm-based heart disease prediction with the help of optimum parameters. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38(1): 451-460. doi:10.17341/gazimmf.977127
- Thai, HT. 2022.** Machine learning for structural engineering: A state-of-the-art review. *Structures*. Elsevier Ltd. doi:10.1016/j.istruc.2022.02.003
- Wang, R., Asghari, V., Cheung, CM., Hsu, SC., Lee, CJ. 2022.** Assessing effects of economic factors on construction cost estimation using deep neural networks. *Automation in Construction*, 134. doi:10.1016/j.autcon.2021.104080
- Yazgılı, E., Baykara, M. 2022.** Türkçe metinlerde makine öğrenmesi yöntemleri ile siber zorbalık tespiti. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. doi:10.17714/gumusfenbil.935448
- Zeynep, AD., Kılıç, E. 2019.** Prediction of Bank Stocks Price with Machine Learning Techniques. *TBV-BBMD*, 12(2): 30-39.