

Türkiye Kamu Projelerinde Yapay Sinir Ağları ile Süre Tahmini

Mehmet S. Kaşka*, Işık Ateş Kırıl**†, Anıl Niş***

* Doktora Öğrencisi, İstanbul Gelişim Üniversitesi, Mimarlık ve Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Avcılar,
İstanbul, Türkiye

E-posta: mskaska@gelisim.edu.tr ORCID: 0009-0000-2700-6873

** Dr. Öğr. Üyesi, Bursa Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, İnşaat Mühendisliği Bölümü, Bursa,
Türkiye

E-posta: ates.kiral@btu.edu.tr ORCID: 0000-0002-5602-8497

*** Doç. Dr., İstanbul Gelişim Üniversitesi, Mimarlık ve Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Avcılar,
İstanbul, Türkiye

E-posta: anis@gelisim.edu.tr ORCID: 0000-0001-9092-8088

Received: 18.11.2024 Accepted: 23.02.2025

Öz - Türkiye'de kamu projelerinde süre tahmini, projenin başarıyla tamamlanması açısından kritik bir rol oynar. Proje süresinin doğru tahmin edilmemesi, maliyet artışlarına ve zaman kayıplarına yol açabilir. Maliyet ve süre arasında güçlü bir ilişki bulunmakta olup, bu ilişkinin doğru modellenmesi proje yönetimi açısından büyük önem taşır. Yapay sinir ağları (YSA), karmaşık ve doğrusal olmayan ilişkileri modelleyebilme kapasitesi ile bu süreçte önemli bir araçtır. Bu çalışmada, Türkiye'deki 25 kamu projesine ait maliyet ve ihaleyi yapan ilgili birim verileri kullanılarak yapay sinir ağı modeli ile süre tahmini yapılmıştır. Elde edilen sonuçlar modelin hızlı ve güvenilir olduğunu göstermektedir.

Anahtar Kelimeler: Proje yönetimi, yapay sinir ağları, maliyet tahmini, süre tahmini, kamu projeleri.

Duration Estimation with Artificial Neural Networks in Turkish Public Projects

Abstract - Duration estimation in public projects in Turkey plays a critical role in the successful completion of the project. Failure to estimate the project duration correctly can lead to cost increases and time losses. There is a strong relationship between cost and duration, and correct modeling of this relationship is of great importance in terms of project management. Artificial neural networks (ANN) are an important tool in this process with their capacity to model complex and non-linear relationships. In this study, duration estimation was made with an artificial neural network model using the cost and tendering unit data of 25 public projects in Turkey. The results obtained show that the model is fast and reliable.

Keywords: Project management, artificial neural networks, cost estimation, duration estimation, public projects.

1. Giriş

Proje yönetimi, projelerin başlangıcından bitimine kadar olan süreçlerin planlanmasını, organize edilmesini ve kontrol edilmesini içerir. Kamu projelerinde, proje süresinin doğru bir şekilde tahmin edilmesi, kaynakların etkin kullanımı ve bütçe aşımının önlenmesi açısından kritik bir öneme sahiptir. Süre tahmini, aynı zamanda proje planlamasında ve karar alma süreçlerinde kilit bir rol oynar.

İnşaat sektörü, yapısı gereği son derece karmaşık, değişken ve rekabetçi bir alandır. Bu sektörde karşılaşılan zorluklar, proje yönetim süreçlerini ve verimliliği önemli ölçüde etkileyebilir. İnşaat projelerinin karmaşıklığı ve sektördeki rekabetin yoğunluğunun, yöneticileri sürekli olarak yeni çözüm arayışlarına yönelttiğini belirtmektedir. İnşaat projeleri, sürekli değişen koşullara uyum sağlamak zorunda olan çok bileşenli ve uzun soluklu süreçleri içerdiği için, geleneksel yöntemlerin bu zorluklarla başa çıkmakta yetersiz kalması olasıdır. [1]

Geleneksel proje yönetim yöntemlerinin ve veri analiz yaklaşımlarının, modern endüstriyel üretimin ihtiyaçlarına artık cevap vermediğini vurgulamaktadır. Bu durum, verimliliğin azalmasına ve projelerde maliyet aşımaları, süre uzamaları gibi sorunlara yol açmaktadır. Geleneksel yaklaşımlar, projelerin karmaşıklığını ele alırken yeterince esnek olmadığından, değişen piyasa koşulları, tedarik zinciri aksaklıkları veya teknik zorluklar karşısında projenin başarısını sağlamakta yetersiz kalmaktadır. [2]

İnşaat projelerinde, yapım süresinin uzun olması, program gecikmeleri ve proje başarısızlıkları, karşılaşılan başlıca riskler arasında yer alır. Dinh ve arkadaşları [3] ile Li ve arkadaşları [2], proje yönetiminde risklerin etkin bir şekilde yönetilmesinin, projenin zamanında ve bütçe dahilinde tamamlanmasında kritik bir rol oynadığını vurgulamaktadır. Proje yönetimi, her bir proje özelinde ihtiyaç duyulan bilgilerin etkin şekilde işlenmesini ve karşılaşılan problemler için stratejik çözümler geliştirilmesini içerir [2]. Başarılı bir inşaat projesi yönetimi, risklerin erken tanımlanması ve etkili bir şekilde ele alınması ile doğrudan ilişkilidir.

Son yıllarda, yapay zeka (YZ) teknikleri, inşaat sektöründeki bu zorluklarla başa çıkmada önemli bir çözüm olarak öne çıkmaktadır. Darko ve arkadaşları [1], yapay zekanın diğer sektörlerde olduğu gibi inşaat projelerinde de karmaşık ve zorlu problemlerin çözülmesine yardımcı olabilecek bir araç olduğunu belirtmektedir. Yapay zeka, büyük veri analizi ve tahmin modelleriyle, projelerin daha etkin yönetilmesine olanak sağlar. Örneğin, inşaat projelerinde süreçlerin daha hızlı analiz edilmesi, risklerin daha doğru bir şekilde tahmin edilmesi ve olası gecikmelerin önceden öngörülmesi, yapay zeka tabanlı sistemler sayesinde mümkün hale gelmiştir.

Yapay zeka tekniklerinin, proje performansını artırmada önemli bir rol oynadığını, özellikle zaman ve maliyet tahminlerinin doğruluğunu geliştirdiğini göstermektedir. Bu tekniklerin kullanılması, insan hatalarının azaltılması, veri odaklı karar verme süreçlerinin iyileştirilmesi ve projelerin

genel başarısını artırmada önemli bir potansiyele sahiptir. [4]

Sonuç olarak, inşaat projelerini yönetmek için yapay zeka ve makine öğrenmesi gibi yeni tekniklerin uygulanması, geleneksel yöntemlere göre daha fazla avantaj sağlamaktadır. Dinh ve arkadaşları [3] ve Li ve arkadaşları [2], yapay zeka tabanlı proje yönetim araçlarının inşaat projelerinde risklerin etkin yönetilmesi ve genel verimliliğin artırılmasında büyük önem taşıdığını vurgulamaktadır. Bu tür yenilikçi yaklaşımlar, inşaat sektöründe rekabet avantajı elde etmek ve projelerin başarı oranını artırmak açısından kritik bir rol oynamaktadır.

Kamu projelerinde teklif veren yükleniciler, doğru bir maliyet analizi yapıp proje süresini isabetli bir şekilde tahmin ederek, projedeki riskleri en aza indirme şansına sahip olurlar. Bu nedenle, mühendislerin hızlı ve doğru süre tahmini yapabilmesi, ihale süreçlerinde stratejik avantaj sağlar. Geleneksel tahmin yöntemlerinin yerini, yapay zeka (YZ) tabanlı yöntemler almakta ve bunlar daha hızlı ve isabetli sonuçlar sunmaktadır. Bu çalışmada, yapay sinir ağları (YSA) modeli kullanılarak, 25 kamu projesinin maliyet ve ihaleyi yapan ilgili idare verilerine dayalı süre tahmini yapılmıştır. Modelin girdisi maliyet ve ihaleyi yapan ilgili idare verileri olup, çıktısı proje süresidir.

2. Yapay Sinir Ağları

Yapay sinir ağları, insan beynindeki sinir hücrelerinin bilgisayar ortamında matematiksel modelleridir. Kullanılan öğrenme algoritmaları, klasik bilgisayar algoritmalarından farklıdır ve insan beyninin sezgisel yeteneklerini yansıtır. Bu nedenle, yapay sinir ağları zaman serisi analizi, optimizasyon, sınıflandırma gibi alanlarda yaygın olarak kullanılmaktadır [5].

Yapay sinir ağları, öğrenme ve keşfetme yeteneklerini otomatik olarak gerçekleştirmek için tasarlanmıştır. Geleneksel programlama yöntemleriyle bu işlemlerin gerçekleştirilmesi zordur. Bu nedenle, YSA'lar genellikle programlanması zor olan durumlar için geliştirilmiş bir disiplin olarak görülmektedir [6].

Sonuç olarak, yapay sinir ağları, biyolojik sinir sisteminin taklit eden etkili bir modelleme tekniği olup, veri sıkıştırma, tanıma ve tahminleme gibi birçok alanda kullanılmaktadır. Geleneksel yöntemler, eksik veya hatalı verilerde sorun yaşarken, YSA'lar karmaşık ilişkileri öğrenme ve genelleme yeteneğine sahiptir [6].


2.1. Yapay Sinir Ağları Genel Yapısı

Yapay sinir hücreleri, yapay sinir ağlarının (YSA) temel bileşenlerini oluşturarak belirli bir düzen içinde bir araya gelirler. Bu yapı, genellikle üç ana katmanda organize edilir: girdi katmanı, ara katmanlar ve çıktı katmanı. Girdi katmanı, dış dünyadan gelen verileri alır ve bunları herhangi bir işlem yapmadan ara katmanlara aktarır. Bazı ağlarda bu katman yalnızca bilgi alımı yapar. Ara katmanlar, girdi katmanından gelen verileri işler ve çıktı katmanına iletir. Bu katmanlar birden fazla olabilir, bu da ağı karmaşıklığını artırarak daha derin öğrenme yetenekleri sağlar. Çıktı katmanı ise, ara katmandan

gelen bilgileri alarak belirli bir girdi setine karşılık gelen çıktıyı üretir ve bu çıktı dış dünyaya gönderilir [6].

Yapay sinir ağları, farklı kriterlere göre sınıflandırılabilir. Bu sınıflandırmalar arasında ağırlık yapısı, ileri beslemeli (feedforward) veya geri beslemeli (feedback) olması, ağırlık matrislerinin simetrik veya asimetrik oluşu, ağırlık değerlerinin sabit veya değişken oluşu, ağda yer alan düğümlerin özellikleri, kullanılan eşik fonksiyonu, düğümlere uygulanan değer türleri (analog, ikili veya sürekli) ve eğitim ya da öğrenme kuralları yer alır [8]. Bu yapılandırmalar, yapay sinir ağlarının farklı problemlere uyum sağlamasına olanak tanır. Özellikle, girdi, ara ve çıktı katmanları ile karmaşık verileri işleyebilme yeteneği, YSA'ların birçok alanda, özellikle makine öğrenimi ve yapay zeka uygulamalarında yaygın olarak kullanılmasını mümkün kılar [7].

Basit bir yapay sinir ağı modeli, Şekil 1'de gösterildiği gibi, girdi ve çıktı katmanlarından oluşan temel bir yapıdır. Bu ağda, her bir girdi birimi (X), çıktıya ulaşmak için kullanılırken, her ağırlık bir veya daha fazla girdi ve çıktı üniteleri bulunmaktadır. Çıktı üniteleri (Ç), tüm girdi üniteleriyle bağlantılıdır ve bu bağlantılar, her bir girdi ile çıktı arasındaki ilişkiyi belirleyen ağırlık değerleri (W) taşır.



Şekil 1. Yapay sinir hücresinin yapısı [7]

2.2. Yapay Sinir Ağları İle İlgili İnşaat Projelerinde Yapılan Çalışmalar

Yapay Sinir Ağları (YSA), inşaat projelerinin yönetimi ve analizinde önemli bir rol oynamaktadır. YSA'nın, karmaşık veri setlerinden öğrenme yeteneği, inşaat mühendisliği alanında çeşitli uygulamalara olanak tanımaktadır. Özellikle, projelerin süre ve maliyet tahminleri konusunda YSA'nın kullanımı, geleneksel yöntemlere göre daha hızlı ve doğru sonuçlar sunmaktadır.

Arslan ve İnce [9] tarafından gerçekleştirilen çalışmada, YSA kullanılarak tek eksenli bileşik eğilme altındaki betonarme kolonların donatı hesabı incelenmiştir. Çalışmada elde edilen sonuçlar, yapay sinir ağlarının bu alandaki uygulamalarında ne kadar etkili olduğunu göstermiştir. YSA, karmaşık donatı hesaplama süreçlerini daha hızlı ve doğru bir şekilde gerçekleştirebilmiştir. Bu, mühendislerin projelerdeki donatı hesaplarını yaparken karşılaştıkları zorlukları azaltmaktadır.

Hegazy ve Aayed [13], inşaat maliyetlerinin tahmin edilmesinde YSA'nın etkinliğini göstermiştir. Bu sayede, bütçe planlaması ve maliyet kontrolü daha etkin bir şekilde gerçekleştirilebilmektedir.

Boussabaine ve Cheetham [14], YSA kullanarak proje sürelerinin tahmin edilmesine yönelik bir çalışma yapmışlardır. Bu tür tahminler, projelerin zamanında tamamlanması için kritik öneme sahiptir.

YSA modeli kullanarak Singapur'daki inşaat projelerinin performansını araştırmıştır. Bu çalışma, ileri beslemeli geri yayımlı bir ağ kullanarak firmaların performansını değerlendiren bir sistem geliştirmiştir. YSA, projelerin çeşitli aşamalarındaki performans verilerini analiz ederek, mühendislerin projelerdeki zayıf noktaları tespit etmesine yardımcı olmuştur. Bu sayede, projelerin daha verimli bir şekilde yönetilmesi mümkün hale gelmiştir [11].

Plak taşıyıcı sistemlerin hem doğrusal hem de doğrusal olmayan analizini YSA kullanarak yapmışlardır. Çalışmaları, bu tür sistemlerin ön boyutlandırma ve optimizasyon problemlerinde kullanılabilirliğini göstermektedir. YSA'nın bu tür mühendislik ve mimari tasarımlarda nasıl kullanılabilirliği, projelerin daha etkin bir şekilde tasarlanmasına ve uygulanmasına olanak tanımaktadır [10].

Graham ve diğerleri [12]t arafından yapılan bir çalışmada, hazır beton dağıtım şebekesi oluşturmak için YSA modeli kullanılmıştır. Bu çalışmada, ileri beslemeli ağlar ile Elman ağı modelinin karşılaştırılması yapılmıştır. Bu tür bir uygulama, beton dağıtım süreçlerinin daha etkili bir şekilde yönetilmesini ve kaynakların daha verimli bir biçimde kullanılmasını sağlamaktadır.

3. Yöntem

Yapay sinir ağları (YSA), öğrenme kabiliyeti ve genelleme yeteneği sayesinde birçok alanda uygulanmaktadır. Temel avantajları arasında bilginin saklanması, örnekler üzerinden öğrenme, matematiksel modele ihtiyaç duymama, eksik veri ile çalışma, sınıflandırma yapabilme ve yeni durumlara adapte olma yer alır [6]. Yapay sinir ağları (YSA'lar) için önemli bir özellik, girdiler ve çıktılar arasındaki ilişkileri öğrenebilmesidir. Eğitim sürecinde ağ, giriş verilerine uygun doğru çıktılar üretmeyi öğrenir [15].

YSA en büyük avantajlarından birisi de deney veya verilerin sonuçlarını direkt olarak kullanarak hesaplamaları öğrenerek sonuç üretebilmesidir. Ayrıca, verileri dağınık veya yetersiz olan ve tanımlanmış bir teorisi olmayan problemlere doğruya yakın çözümler sağlamasıdır [16].

Bu çalışma kapsamında, YSA kullanılarak maliyete dayalı süre tahminleri yapılmıştır. Veri setinde, kamu ihalelerine ait 25 proje incelenmiştir. Girdi verisi olarak projelerin maliyetleri ve ilgili idare türü alınmış, çıktı olarak ise projelerin tamamlanma süreleri kullanılmıştır. YSA modeli, bu girdilerle eğitilerek, proje

süresi üzerinde etkili olan faktörleri öğrenmiş ve süre tahminleri yapmıştır.

Veri seti, rastgele bir şekilde üç bölüme ayrılmıştır: eğitim seti, doğrulama seti ve test seti. Eğitim seti, modelin eğitildiği veri setidir; burada 25 gözlemden 15'i eğitim için kullanılmıştır. Doğrulama seti, modelin eğitim esnasında genelleme kabiliyetini değerlendirmek için kullanılan bir set olup, 5 gözlem doğrulama setine ayrılmıştır. Bu set, aşırı öğrenmeyi (overfitting) önlemeye yardımcı olur. Test seti ise modelin tamamen bağımsız ve hiç görmediği veriyle test edildiği set olup, son 5 gözlem test setine ayrılmıştır. Rastgele veri bölme işlemi, eğitim, doğrulama ve test setlerinin her seferinde farklı veri örneklerinden oluşmasını sağlar; bu da modelin genelleme yeteneğini daha iyi anlamaya yardımcı olur.

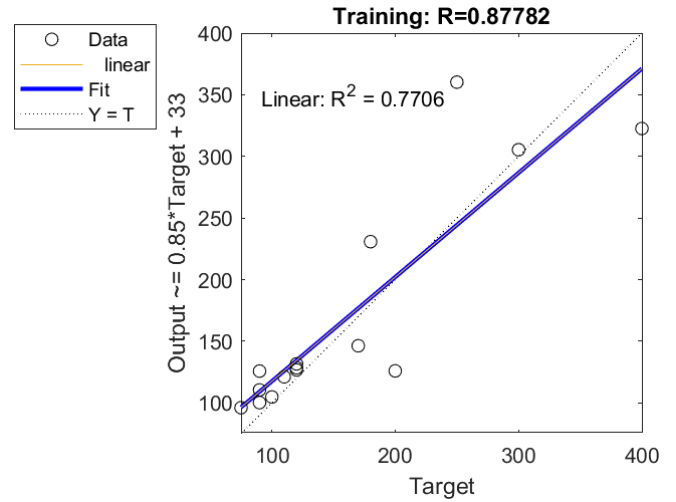
Eğitim algoritması olarak Scaled Conjugate Gradient (SCG) kullanılmıştır. Bu algoritma, yapay sinir ağlarının eğitilmesinde kullanılan optimize edilmiş bir öğrenme algoritmasıdır. Klasik algoritmalarla karşılaştırıldığında, SCG daha hızlı bir öğrenme süreci sunar ve özellikle ikinci derece türev bilgisine (Hessian matrisi) gerek duymadan türev kullanarak daha verimli optimizasyon sağlar. SCG, ağırlık güncellemelerinde eşlenik gradyan (conjugate gradient) kullanarak öğrenme hızını optimize eder ve büyük veri setlerinde hesaplama maliyetini azaltmak için tercih edilir. Ayrıca, SCG algoritması aşırı öğrenmeyi önlemede yardımcıdır ve yüksek boyutlu parametre uzaylarında iyi performans gösterir.

Modelin performansı, Mean Squared Error (MSE) ile ölçülmüştür. MSE, modelin tahmin ettiği değerlerle gerçek değerler arasındaki farkın karesinin ortalamasını alarak modelin doğruluğunu ölçer. Düşük MSE değerleri, modelin daha doğru tahminler yaptığını gösterir. Eğitim ve doğrulama süreci boyunca MSE değerleri izlenmiş ve modelin genel performansı değerlendirilmiştir. Bu süreçte, veri setindeki ilişkileri öğrenmek ve aşırı öğrenmeyi önlemek amaçlanmıştır.

4. Bulgular


Bu bölümde, yapay sinir ağı modeli ile yapılan süre tahminlerinin sonuçları sunulmuştur. 25 kamu projesi üzerinde yapılan analizlerde, maliyet ve süre verileri arasındaki ilişki incelenmiş ve modelin tahmin performansı değerlendirilmiştir.

Türkiye'deki kamu projelerinin maliyet verilerine dayalı olarak yapay sinir ağı (YSA) modeli ile yapılan süre tahminlerinin sonuçları dört farklı set (eğitim, doğrulama, test ve tüm veri) için sunulmaktadır. Her bölümde modelin başarısı korelasyon katsayısı (R) ve determinasyon katsayısı (R^2) ile değerlendirilmektedir.




Şekil 2. Eğitim seti sonuçları

Eğitim seti (Training), modelin öğrenme sürecinde kullanılan verileri temsil eder. Korelasyon katsayısı $R=0.87782$, modelin eğitim verileri üzerinde hedef değerlerle tahmin edilen değerler arasında güçlü bir doğrusal ilişki olduğunu gösterir. Determinasyon katsayısı $R^2=0.7706$, modelin eğitim verilerinde %77 oranında hedef değişkenin varyansını açıkladığını gösterir. Yani, modelin tahmin yeteneği oldukça iyidir ve düz çizgiyle gösterilen tahminler gerçek veri noktalarına yakın bir şekilde yer almaktadır.



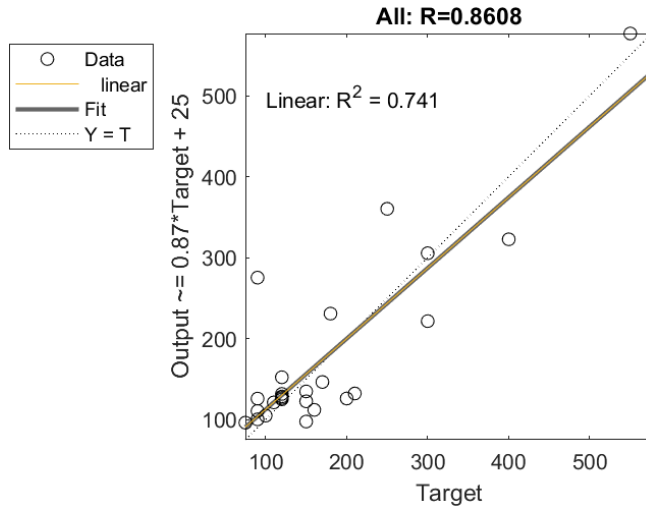
Şekil 3. Doğrulama seti sonuçları

Doğrulama seti (Validation), modelin yeni ve daha önce görmediği veriler üzerindeki performansını ölçmek için kullanılır. Korelasyon katsayısı $R=0.95422$, modelin doğrulama verileri üzerinde çok güçlü bir doğrusal ilişki kurduğunu gösterir. $R^2=0.9105$ ise modelin doğrulama verilerindeki hedef değişkenin %91'ini açıkladığını ifade eder. Bu sonuç, modelin genelleme yeteneğinin çok yüksek olduğunu gösterir. Düz çizgi, modelin tahminlerini ve daireler gerçek verileri temsil eder; model tahminleri hedefe oldukça yakındır.



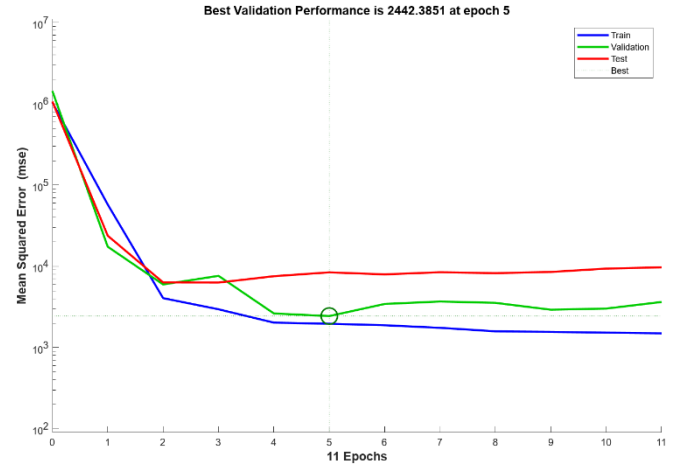
Şekil 4. Test seti sonuçları

Test seti, modelin hiç görmediği veriler üzerinde yapılan performans değerlendirmesidir. Korelasyon katsayısı R=0.87589, test verileri üzerinde güçlü bir doğrusal ilişki olduğunu gösterir. R²=0.7672, modelin test verilerindeki hedef değişkenin %76.7'sini açıkladığını ortaya koyar. Düz çizgi modelin tahminlerini, daireler ise test verisindeki gerçek değerleri ifade eder. Model, eğitimde öğrendiği bilgiyi yeni veriler üzerinde de başarıyla uygulamaktadır.



Şekil 5. Tüm veri seti sonuçları

Tüm veri seti (All), eğitim, doğrulama ve test verilerinin birleştirilmiş halini gösterir. Korelasyon katsayısı R=0.8608, tüm veri setinde tahmin edilen değerlerle gerçek değerler arasında güçlü bir ilişki olduğunu ifade eder. R²=0.7409 ise tüm veri setinde modelin hedef değişkenin %74'ünü açıkladığını gösterir. Bu, modelin genel performansının yüksek olduğunu kanıtlar. Düz çizgi, modelin tüm veri üzerindeki tahminlerini ve daireler gerçek verileri gösterir.



Şekil 6. Doğrulama performansı grafiği

Bu grafikte, yapay sinir ağı modelinin eğitim sürecindeki performansı, ortalama kare hata (MSE) metriği üzerinden değerlendirilmektedir. Grafik, eğitim (train), doğrulama (validation) ve test verileri üzerindeki hataların iterasyonlar boyunca nasıl değiştiğini göstermektedir.


X Eksenini modelin eğitim sürecinde kaç iterasyon geçtiğini gösterir. 1 iterasyon, tüm veri setinin model tarafından bir kez işlenmesi anlamına gelir. Grafikte toplam 11 iterasyon gözlemlenmiştir.

Y Eksenini modelin tahmin ettiği değerlerle gerçek değerler arasındaki ortalama kare hatayı (MSE) ifade eder. Y eksenini logaritmik ölçekte (10⁷ ile 10² arasında) yer alır ve hata miktarındaki düşüşün daha net gözlemlenmesini sağlar. Düşük MSE, modelin daha iyi performans gösterdiğini ifade eder.

Grafik üzerinde modelin doğrulama setinde en düşük hatayı (en iyi performansı) verdiği iterasyon vurgulanmıştır. Bu noktada doğrulama hatası (MSE) en düşük değere ulaşmış ve modelin genelleme kabiliyetinin en iyi olduğu an tespit edilmiştir. Modelin en iyi doğrulama performansının 5. iterasyonda gerçekleştiği gözlemlenmiştir. (MSE = 2442.3851). Doğrulama hatası bu noktada minimum seviyededir. Bu, modelin doğru bir şekilde genelleme yapabildiğini gösterir.

İlk iterasyonda eğitim, doğrulama ve test setlerindeki hatalar oldukça yüksektir (yaklaşık 10⁷ civarında). Bu, modelin başlangıçta veriyi iyi öğrenemediğini, ancak birkaç iterasyondan sonra hataların hızla azaldığını gösterir.

Genelde, doğrulama hatasının en düşük seviyeden sonra tekrar artış göstermesi durumunda overfitting(aşırı öğrenme) olduğu söylenir. Bu grafikte, 5. iterasyondan sonra doğrulama hatasında çok fazla artış gözlemlenmemektedir, ancak test seti üzerindeki hata bir miktar sabitlenmektedir. Bu da modelin overfitting'e çok meyilli olmadığını gösterir.



Şekil 7. Hata histogram grafiği

Grafikte, kamu projelerinin maliyet verilerine dayalı olarak yapılan süre tahminlerinin hatalarını gösteren bir histogram yer almaktadır. Histogramda hatalar, hedef değerlerle modelin tahmin ettiği değerler arasındaki farkları (Errors = Targets - Outputs) temsil eder. Bu farklar 20 ayrı kategori içinde toplanmıştır.

X Eksenini (Errors) hataların büyüklüğünü ifade eder. Sol taraf büyük negatif hataları (modelin tahmini gerçekte olduğundan çok daha düşük), sağ taraf ise pozitif hataları (modelin tahmini gerçekte olduğundan daha yüksek) gösterir.

Y Eksenini (Instances) her bir hata kategorisindeki örnek sayısını gösterir. Yani, belirli bir hata büyüklüğünde kaç örneğin bulunduğu ifade eder.

Sıfır hata (0) eksenini, modelin tahminlerinin gerçek değerlerle birebir eşleştiği noktayı gösterir. Grafikteki çubuklar sıfır hata çizgisine ne kadar yakınsa, model o kadar doğru tahminlerde bulunmuş demektir.

Histogramın merkezinde, hataların sıfıra yakın olduğu bir bölge dikkat çekmektedir (örneğin -7.235 hata kategorisi). Bu bölgede eğitim (mavi), doğrulama (yeşil) ve test (kırmızı) verileri üzerindeki hataların toplandığı görülmektedir. Sıfıra en yakın bu hata bölgesinde en fazla örneğin yer alması, modelin çoğunlukla doğru tahminlerde bulunduğunu göstermektedir.

Sol taraftaki negatif değerler modelin hedeften düşük tahminler yaptığı durumları gösterir. Özellikle -33.61 ve -20.42 hata kategorilerinde belirgin bir hata sayısı mevcuttur, ancak bu hataların sayısı sınırlıdır ve genellikle daha düşük hatalar alınmıştır.

Sağ taraftaki pozitif hatalar modelin hedeften yüksek tahminler yaptığı durumları gösterir. Örneğin 58.69 ve 71.88 hata kategorilerinde bazı hatalar göze çarpmaktadır. Ancak bu pozitif hatalar da sayıca çok fazla değildir.

5. Tartışma

Modelin her bir veri setindeki performansı yüksek korelasyon katsayıları ile gösterilmiştir. R değerleri, modelin hedefle tahminler arasında güçlü doğrusal ilişkiler kurduğunu ifade eder. Özellikle doğrulama setindeki $R=0.95422$ değeri, modelin genelleme başarısının çok yüksek olduğunu göstermektedir.

Hedef değişkenin açıklanan varyans oranını gösteren R^2 değerleri, her set için %74 ile %91 arasında değişmektedir. Yüksek R^2 değerleri, modelin her veri setinde oldukça güçlü tahminler yaptığını doğrulamaktadır.

Sonuç olarak, yapay sinir ağı (YSA) modeli, maliyet verilerine dayalı süre tahminlerinde güvenilir ve güçlü bir araç olarak öne çıkmaktadır. Eğitim, doğrulama ve test verileri üzerindeki yüksek R ve R^2 değerleri, modelin hem öğrenme aşamasında hem de yeni veriler üzerinde başarılı olduğunu kanıtlar. Özellikle doğrulama setindeki performansın çok yüksek olması, modelin aşırı öğrenmeden (overfitting) kaçınarak genelleme kapasitesinin yüksek olduğunu göstermektedir.

Grafik, modelin doğrulama setindeki en iyi performansı 5. iterasyonda yakaladığını ve ardından modelin eğitim ve test verileri üzerinde dengeli bir şekilde çalıştığını göstermektedir. Eğitim sürecinde doğrulama hatasının artmaması, modelin genelleme kabiliyetinin iyi olduğunu ve overfitting yapmadığını göstermektedir.

Genel olarak, YSA modelinin yaptığı hataların büyük bir kısmı sıfıra yakın bölgede toplanmıştır. Bu, modelin gerek eğitim, doğrulama, gerekse test verileri üzerinde genellikle doğru tahminlerde bulunduğunu göstermektedir. Yüksek ve aşırı hataların sayısı azdır ve bu da modelin genel performansının oldukça iyi olduğunu kanıtlamaktadır. Modelin sıfır hata eksenine yakın tahminler yaptığı alanlar, özellikle modelin güvenilirliğini ortaya koymaktadır.

Grafiklerle desteklenen sonuçlar, kamu projelerinde YSA'nın başarılı tahminler sunduğunu göstermektedir.

6. Sonuç

Bu çalışma, Türkiye'deki kamu projelerinde yapay sinir ağları kullanılarak maliyet ve ihaleyi yapan ilgili idare verilerine dayalı süre tahmini yapılmasını amaçlamaktadır. Yapılan analizler, YSA'nın proje sürelerini tahmin etmek için hızlı ve güvenilir bir yöntem olduğunu ortaya koymuştur. 25 kamu projesine ait maliyet ve ilgili idare verilerinin kullanılması ile gerçekleştirilen bu çalışma, gelecekte yapılacak projelerde süre tahmininde yapay sinir ağlarının etkili bir araç olarak kullanılabilirliğini göstermektedir. Modelin sağladığı yüksek doğruluk oranı, kamu ihaleleri sürecinde daha rekabetçi tekliflerin verilmesine ve projelerdeki risklerin minimize edilmesine katkı sağlayabilir.

Kamu projelerinde süre tahminlerini daha kapsamlı hale getirmek için farklı veri türlerinin analize dahil edilmesi faydalı olacaktır. Proje büyüklüğü, örneğin inşaat alanı veya hacmi, proje süresini doğrudan etkileyen faktörler arasında yer alır. Bunun yanında, proje türü (konut, altyapı, enerji gibi) ve

kullanılan ekipman ve işgücü miktarı gibi kaynak verileri de süre tahminlerine katkı sağlayabilir. Mevsimsel ve hava durumu verileri, özellikle dış mekan projelerinde süreyi uzatabilen kritik değişkenlerdir. Projenin sözleşme koşulları, ihale şartları ve idari bürokratik süreçler de projelerin zamanlamasında önemli rol oynar. Aynı şekilde, malzeme tedarik süreleri, lojistik sorunlar ve finansal durum da gecikmelere neden olabilir. Ayrıca, projelerde karşılaşılan riskler, kazalar veya doğal afetler gibi beklenmedik olaylar ve bu tür durumlarla ilgili alınan önlemler de süre tahminlerinde dikkate alınmalıdır. Tüm bu ek verilerin analize dahil edilmesi, yapay sinir ağı modellerinin daha doğru ve kapsamlı süre tahminleri yapmasına olanak tanıyacaktır.

Kaynaklar

- [1] Darko, A., Chan, A.P.C., Adabre, M.A., Edwards, D.J., Hosseini, M.R., Ameyaw, E.E., (2020). Artificial Intelligence in The AEC Industry: Scientometric Analysis and Visualization of Research Activities. *Automation in Construction*, 112
- [2] Li, W., Duan, P., Su, J., (2021). The Effectiveness of Project Management Construction with Data Mining and Blockchain Consensus, *Journal of Ambient Y. Yorozu, M. Hirano, K. Oka, and Y. Tagawa, "Electron spectroscopy studies on magneto-optical media and plastic substrate interface", IEEE Transl. J. Magn. Japan, vol. 2, pp. 740-741, August 1987. (Article)*
- [3] Dinh, T.T.A., Liu, R., Zhang, M., (2018). Untangling Blockchain: A Data Processing View of Blockchain Systems. *IEEE Trans Knowl Data Eng* 30(7):1366–1385
- [4] Hosny, O.A., Elbarkouky, M.M.G, Elhakeem, A., (2005). Construction Claims Prediction and Decision Awareness Framework using Artificial Neural Networks and Backward Optimization, *Journal of Construction Engineering and Project Management*.
- [5] Warner, Brad, Manavendra Misra; (1996), "Understanding Neural Networks as Statistical Tools", *The American Statistician*, 50 (4), pp.284-293
- [6] Öztemel, Ercan; (2003), *Yapay Sinir Ağları*, Birinci Baskı, İstanbul: Papatya Yayıncılık.
- [7] Kohonen, T. (1987). "Int. Conf. on AI", *State of the Art in Neural Computing*.
- [8] Şen, Z. (2004). *Yapay Sinir Ağları İlkeleri*, Su Vakfı Yayınları, İstanbul.
- [9] Arslan, A. ve İnce, R., 1993. Geriye Yayılma Yapay Sinir Ağı Kullanılarak Betonarme Kolonların Tasarımı, *Turkish Journal of Engineering and Environmental Sciences*, 2, 127-135.
- [10] Civalek, Ö. ve Ülker, M., 2004. Dikdörtgen Plakların Doğrusal Olmayan Analizinde Yapay Sinir Ağı Yaklaşımı, *İMO Teknik Dergi*, 15(1), 3171-3190.
- [11] Ling, F.Y.Y., Liu, M., 2004. Using neural network to predict performance of design-build projects in Singapore, *Building and Environment*, 39, 1263-1274.
- [12] Graham, L.D., Forbes, D.R., Smith, S.D., 2006. Modeling the ready mixed concrete delivery system with neural networks, *Automation in Construction*, 15, 656 – 663.
- [13] Hegazy, T., Ayed, A., 1998. Neural Network Model for Parametric Cost Estimation of Highway Projects, *Journal of Construction Engineering and Management*, 124, 210– 218.
- [14] Boussabaine, A.H., Cheetham, D.W., 1995. Artificial Neural Networks: A Tool for Predicting Project Durations, *Proceedings of the Association of Researchers in Construction Management*, September 1995, 543-559.
- [15] Alkan A., *Predictive Data Mining with Neural Networks and Genetic Algorithms*, Ph.D. Thesis, İTÜ, İstanbul, 2001, 51.
- [16] Hasgül, Özlem, ve A. Sermet Anagün. "Deneysel Sonuçların Analizinde Yapay Sinir Ağları Kullanımı ve Beton Dayanım Testi İçin Bir Uygulama."