

Temporal Fusion Transformer (TFT) Kullanılarak İnşaat Maliyet Endeksi Öngörüsü

Özer Özaydın¹

İrem Varürer²

Özet

Bu çalışmada, derin öğrenme modellerinden biri olan Temporal Fusion Transformer (TFT) mimarisi kullanılarak Türkiye'ye ait aylık İnşaat Maliyet Endeksi (İME) öngörüsü gerçekleştirilmeye çalışılmıştır. Burada, günümüzde öngörüde kullanılan derin öğrenme modellerinden biri olan TFT modelini tanıtmak ve inşaat maliyet endeksi öngörüsünde kullanarak performansını görmek amaçlanmıştır. İME öngörüsü için, Ocak 2015-Eylül 2025 zaman aralığında aylık veriler kullanılmıştır. Ayrıca, maliyet dinamiklerini etkileyebileceği değerlendirilen üç bağımsız değişken (inşaat yapı sayısı (m^2)), sanayi üretim endeksi, konut satış endeksi) seçilerek modele dâhil edilmiştir. Öngörüde TFT modeli kullanılırken, model performansı Kök Ortalama Kare Hata (RMSE) metriği ile değerlendirilmiştir. TFT modelinin RMSE değeri 36,01 olarak bulunmuştur. Elde edilen bulgular, TFT modelinin hem kısa vadeli öngörülerde hem de tüm dönem performansında yüksek doğruluk sağladığını ve trend ile volatilité dinamiklerini başarılı biçimde yakaladığını göstermektedir. Ayrıca değişken önem analizi sayesinde, inşaat maliyetlerini etkileyen temel göstergelerin görece katkıları nicel olarak ortaya konulmuştur.

1. Giriş

Türkiye ekonomisinin yapısal dinamikleri incelendiğinde, inşaat sektörünün yalnızca bir üretim alanı değil, aynı zamanda büyümenin temel taşıyıcısı ve istihdamın ana kaynağı olduğu görülmektedir. Ancak sektörün bu rolü, makroekonomik dalgalanmalara karşı aşırı hassasiyet göstermesiyle doğrudan ilişkilidir. Özellikle son yıllarda küresel ve yerel düzlemde yaşanan

1 Dr. Öğr. Üyesi, Eskişehir Osmangazi Üniversitesi Fen Fakültesi İstatistik Bölümü, oozaydin@ogu.edu.tr, ORCID ID: 0000-0001-6657-1162

2 Uzman İstatistikçi, irem.1997.rvr@gmail.com, ORCID ID: 0000-0001-9788-1729

maliyet artışları, İnşaat Maliyet Endeksi'nin (İME) takibini ve geleceğe yönelik projeksiyonlarını stratejik bir zorunluluk haline getirmiştir. Malzeme fiyatlarındaki volatilité ve işçilik giderlerindeki yukarı yönlü ivme, proje bütçelerinin yönetimini güçleştirirken, sektör paydaşlarını daha sofistike ve güvenilir öngörü metodolojileri aramaya sevk etmektedir.

Geleneksel ekonometrik modeller, maliyet değişimlerini çoğunlukla geçmiş verilere dayalı doğrusal bir düzlemde analiz etme eğilimindedir. Oysa inşaat maliyetleri; sanayi üretiminden konut talebine, ruhsatlandırılan yapı stokundan döviz bazlı girdi maliyetlerine kadar çok katmanlı ve doğrusal olmayan bir değişkenler kümesi tarafından manipüle edilmektedir. Bu noktada yapay zeka disiplini, karmaşık veri yığınları arasındaki kaotik ilişkileri çözme yeteneğiyle öne çıkmaktadır.

Günümüzde yapay zeka, teknolojik bir inovasyon olmanın ötesine geçerek, operasyonel verimliliği ve stratejik karar alma süreçlerini optimize eden bütüncül bir paradigma haline gelmiştir. Bu dönüşümün odağında yer alan makine öğrenmesi ve derin öğrenme disiplinleri, veriden anlamlı örüntüler çıkarma yetenekleri sayesinde her geçen gün daha geniş bir uygulama alanı bulmaktadır. Yapay zeka teknolojilerinin toplumsal ve etik yansımaları üzerine yürütülen “fayda-zarar” eksenindeki tartışmalar devam etse de, bu sistemlerin modern yaşantının her katmanına entegre olduğu yadsınamaz bir gerçektir. Bireylerin gündelik tercihlerinden karmaşık endüstriyel süreçlere kadar uzanan bu dijital yenilik, yapay zekayı ve derin öğrenme modellerini bir çok alan için inkâr edilemez bir kolaylaştırıcı unsur olarak konumlandırmıştır.

Derin öğrenme tabanlı yaklaşımlar, verinin içerisindeki gürültüyü (noise) filtreleyerek, geleneksel yöntemlerin ıskaladığı gizli korelasyonları açığa çıkarma potansiyeline sahiptir. Özellikle zaman serisi analizlerinde de çokça yapılan maliyet öngörü süreçlerinde gösterdiği kararlı ve istikrarlı yaklaşımları ile güvenilir bir karar destek sistemine dönüşmesini sağlamıştır.

Bu çalışma, Türkiye'deki İME'nin seyrini, derin öğrenme literatürünün en güncel ve güçlü mimarilerinden biri olan Temporal Fusion Transformer (TFT) modeli ile analiz etmeyi amaçlamaktadır. Ayrıca, çok değişkenli bu veri seti TFT modelinin “dikkat mekanizması” (attention mechanism) ile işlenerek şeffaf bir şekilde hangi makroekonomik parametrenin maliyetler üzerinde ne zaman ve ne ölçüde etkili olduğunu da göstermek amaçlanmıştır. Özellikle karmaşık çok değişkenli zaman serisi veri setlerinde çok iyi sonuçlar verdiği bilinen TFT modelinin güçlü ve istikrarlı yapısı bu çalışmada gösterilmeye çalışılmış olup, daha yeni bir model olması sebebi ile üzerine yapılan çalışma sayısının azlığından dolayı literatüre katkısı olacağı düşünülerek bu çalışma için özellikle seçilmiştir.

2. Literatür Taraması

Aydınlı (2022), tarafından gerçekleştirilen çalışma, Türkiye’de inşaat maliyet endeksinin öngörü performansını irdelemek amacıyla 2015–2022 arasındaki İME verilerini kullanarak zaman serisi modellerinin etkinliğini değerlendirmiştir. Araştırmada Holt-Winters Üstel Düzeltme ve ARIMA gibi klasik zaman serisi yöntemleri ile inşaat maliyet endeksinin ileriye dönük öngörüsü yapılmış; sonuçlar, yüksek enflasyon ortamında bu modellerin performansının sınırlı olduğunu göstermiştir. Ancak özellikle üçlü üstel düzeltme (Holt-Winters) modelinin görece olarak daha iyi öngörüler verdiği bulunmuştur. Yazar, bu bağlamda daha ileri makine öğrenmesi ve derin öğrenme tabanlı modellerin entegrasyonunun maliyet öngörü performansını artırabileceğini vurgulamıştır.

Aslam ve ark. (2023), tarafından yürütülen çalışma gelişmekte olan ülkelerde bina malzemeleri İME’ sinin öngörüsü üzerine odaklanmıştır. Çalışmada Pakistan için geçmiş 2000–2020 dönemine ait İME verileri kullanılmış, bu veriler çimento, çelik, tuğla, kum ve çakıl gibi malzemelerin fiyat endekslerini içermiştir. Yapay Sinir Ağları (ANN), regresyon ve klasik zaman serisi modelleri karşılaştırılmış ve swish aktivasyon fonksiyonu ile geliştirilmiş ANN modeli, diğer iki yaklaşıma göre daha düşük hata oranları (ME, MAE ve Theil’s U) ile daha güvenilir İME öngörülerini sağlamıştır. Yazarlar, tekrarlayan sinir ağlarının (ör. LSTM) bu doğruluğu daha da artırabileceğini belirtmişlerdir.

Tüz ve Ebese (2023), çalışması Türkiye’de İnşaat Maliyet Endeksi’nin (İME) öngörüsü üzerine odaklanmıştır. Bu çalışmada 2005–2019 dönemine ait İME zaman serisi verileri kullanılmış, en yüksek öngörü doğruluğuna ulaşmak için klasik zaman serisi modellerinden Holt-Winters üstel düzeltme modeli, Parçacık Sürü Optimizasyonu (PSO) ile optimize edilmiş ve Walk-Forward Cross-Validation (WFCV) ile parametre ayarları iyileştirilmiştir. Modelin optimizasyonu sonucunda eğitim verilerinde düşük hata ve İME öngörüsünde güçlü performans elde edilmiş; mevsimsellik etkisinin ihmal edilebileceği ve optimize edilmiş Holt-Winters modelinin inşaat maliyet öngörüsünde etkin bir şekilde kullanılabilirliği gösterilmiştir. Bu çalışma, Türkiye özelinde İME öngörüsü için optimize edilmiş klasik modellerin uygulanabilirliğini ortaya koymaktadır.

Bui ve Ngo (2024) çalışması, inşaat maliyet endekslerinin (Construction Cost Index, CCI) öngörüsü için derin öğrenme yaklaşımlarını incelemiştir. Bu çalışmanın amacı, özellikle yüksek enflasyon ortamında inşaat sektöründeki paydaşlar için güvenilir bir maliyet öngörü aracı sunmaktır. Çalışmada geçmiş İME değerleri üzerinde uzun-kısa süreli bellek (LSTM) ağı kullanılarak model eğitilmiş ve bu derin öğrenme modelinin İME öngörüsünde etkili bir yöntem olduğu vurgulanmıştır; modelin özellikle kısa vadeli öngörülerde geleneksel

yöntemlere göre daha iyi performans gösterdiği belirtilmiştir. Bu araştırma, İME öngörüsü bağlamında derin öğrenme uygulamalarına yönelik önemli bir giriş niteliği taşımaktadır.

Wang ve ark. (2025) tarafından yapılan çalışma, özellikle Highway Construction Cost Index (HCCI) gibi dalgalı maliyet serilerinin öngörülmesinde hibrit bir çerçeve önermektedir. Araştırmada Texas HCCI zaman serisi verisi kullanılmış ve bu veri VMD (Variational Mode Decomposition) ile bileşenlere ayrıldıktan sonra LSTM daha düzgün bileşenleri, GRU (Gated Recurrent Unit) ise daha değişken bileşenleri öngörmek üzere eğitilmiştir. Elde edilen sonuçlar, bu VMD–LSTM–GRU hibrit modelinin yalnızca klasik zaman serisi modellerine değil, ayrıca tek başına derin öğrenme modellerine kıyasla da daha yüksek öngörü doğruluğu sunduğunu göstermiştir ve bu performans artışı, bütçe planlaması ve finansal karar destek sistemleri için önemli bir gelişme olarak yorumlanmıştır.

3. Materyal ve Yöntem

Bu çalışmada Türkiye’de inşaat sektörünün maliyet dinamiklerini ileriye dönük olarak öngörebilmek amacıyla İnşaat Maliyet Endeksi (İME) esas alınmıştır. İnşaat sektörü; istihdam, ekonomik büyüme, konut piyasası ve kamu yatırımları üzerindeki doğrudan ve dolaylı etkileri nedeniyle makroekonomik yapı içerisinde stratejik bir konuma sahiptir. Özellikle son yıllarda küresel emtia fiyatlarındaki artışlar, döviz kuru dalgalanmaları ve enflasyonist baskılar, inşaat maliyetlerinde belirgin oynaklıklara yol açmıştır. Bu durum, maliyet öngörülerinin hem politika yapıcılar hem de yatırımcılar açısından kritik önem taşımaya neden olmaktadır. Dolayısıyla İME’nin doğru ve güvenilir biçimde öngörülmesi, sektörel risk yönetimi ve stratejik planlama süreçlerine önemli katkı sağlayacaktır.

Çalışmada bağımlı değişken olarak Türkiye İstatistik Kurumu (TÜİK) tarafından yayımlanan aylık İnşaat Maliyet Endeksi kullanılmıştır. Veri seti aylık verilerden oluşup, Ocak 2015- Eylül 2025 dönemini kapsamakta olup toplam 130 gözlemden oluşmaktadır. Modelin açıklayıcı gücünü artırmak amacıyla yalnızca geçmiş endeks değerleri değil, aynı zamanda inşaat maliyetlerini etkileyebileceği düşünülen çeşitli makroekonomik ve finansal göstergeler bağımsız değişken olarak modele dahil edilmiştir. Bu kapsamda inşaat yapı sayısı (m^2), sanayi üretim endeksi, konut satış endeksi kullanılmıştır. Böylece modelin, maliyet dinamiklerini tek değişkenli bir yapıdan ziyade çok değişkenli bir çerçevede öğrenmesi amaçlanmıştır.

Öngörü için klasik istatistiksel teknikler yerine yapay zeka araçları içerisinde derin öğrenme modellerinden TFT kullanılmıştır. Çalışma Python programlama dilinde gerçekleştirilmiştir.

Günümüzde yapay zeka, yalnızca teknik bir disiplin olmanın ötesine geçerek, sosyo-teknik sistemlerin merkezinde yer alan ve insan bilişini simüle eden bir paradigma haline gelmiştir. İnsanın deneyim odaklı karar verme mekanizması—örneğin dış dünyadan gelen verileri (hava durumu, bulut yoğunluğu vb.) işleyerek stratejik bir eylem (şemsiye alma) geliştirmesi—aslında karmaşık bir veri işleme ve örüntü tanıma sürecidir. Yapay zeka çalışmalarının temelinde de bu bilişsel sürecin bilgisayar ortamında temsil edilebilmesi yer almaktadır. Başka bir ifadeyle amaç, insanın karar verme biçimini taklit eden sistemler geliştirmektir.



Şekil 1. Yapay zeka ve bağlantılı kavramlar

Literatürde yapay zeka; bilgisayarların veya bilgisayar destekli sistemlerin, öğrenme, akıl yürütme ve problem çözme gibi insana özgü süreçleri gerçekleştirebilmesi şeklinde tanımlanmaktadır (Öztürk ve Şahin, 2018). Kavramın resmi olarak 1955 yılında Dartmouth College'daki bir çalışmada dile getirildiği bilinmektedir. Bununla birlikte, kuramsal arka planının daha erken dönemlere uzandığını söylemek mümkündür. Özellikle 1943 yılında McCulloch ve Pitts tarafından geliştirilen matematiksel nöron modeli, insan beyninin işleyişini soyut bir düzlemde temsil etmeye yönelik ilk sistematik adımlardan biri olmuştur (Güney, 2022).

Yapay zekanın gelişim süreci kesintisiz bir ilerleme şeklinde gerçekleşmemiştir. Özellikle erken dönemlerde donanım kapasitesinin sınırlı olması ve veri eksikliği

önemli engeller oluşturmuştur. Ancak zamanla işlem gücünün artması ve büyük veri kaynaklarının erişilebilir hale gelmesi, alanın yeniden ivme kazanmasına katkı sağlamıştır.

Günümüzde karmaşık yapay zeka modellerinin temelini daha önce de belirtildiği gibi, 1943 yılında McCulloch ve Pitts tarafından geliştirilen matematiksel nöron modeli oluşturmaktadır. Söz konusu modeller temelde Yapay Sinir Ağları (YSA) olarak isimlendirilmektedir.

3.1. Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beynindeki nöral bağlantı yapısından esinlenerek oluşturulan matematiksel modellerdir. Bu modellerin temel amacı, verideki örüntüleri keşfetmek ve bu örüntüler üzerinden genelleme yapabilmektir. Günümüzde görüntü tanıma, ses işleme, sınıflandırma ve zaman serisi öngörüsü gibi birçok farklı problem türünde kullanılmaktadır.

Basit bir sinir ağı yapısında, giriş verileri belirli ağırlık katsayılarıyla çarpılarak doğrusal bir birleşim elde edilir. Bu birleşime yanlılık terimi eklenir ve sonuç bir aktivasyon fonksiyonundan geçirilerek çıktı üretilir. Modelin ürettiği çıktı ile gerçek değer arasındaki fark, hata fonksiyonu aracılığıyla hesaplanır ve ağ parametreleri bu hatayı azaltacak biçimde güncellenir. Öğrenme süreci genellikle yinelemeli bir optimizasyon mekanizmasına dayanır ve model performansı belirli bir denge noktasına ulaştığında süreç sonlandırılır (McCulloch ve Pitts, 1943).

YSA'lar farklı ölçütlere göre sınıflandırılabilir. Bağlantı yönüne göre ileri beslemeli ve geri beslemeli yapılar; katman sayısına göre ise tek katmanlı ve çok katmanlı ağlar ayırt edilmektedir. Özellikle çok katmanlı ağların geliştirilmesi, daha karmaşık ilişkilerin modellenmesini mümkün kılmış ve derin öğrenme yaklaşımının ortaya çıkmasına zemin hazırlamıştır (Üntez, 2022).

3.2. Derin Öğrenme

Derin öğrenme, çok katmanlı sinir ağlarına dayanan ve veriden temsilleri aşamalı olarak öğrenebilen bir makine öğrenmesi yaklaşımıdır. Bu yöntemde model, ham veriden başlayarak daha soyut özellikleri katmanlar aracılığıyla kademeli biçimde çıkarmaktadır. Dolayısıyla öznitelik çıkarımı sürecinin önemli bir kısmı doğrudan model tarafından gerçekleştirilmektedir (Güney, 2022).

Makine öğrenmesi ile derin öğrenme arasındaki temel farklardan biri burada ortaya çıkmaktadır. Geleneksel makine öğrenmesi yöntemlerinde verinin modele uygun biçimde dönüştürülmesi ve özniteliklerin belirlenmesi çoğunlukla araştırmacının sorumluluğundadır. Buna karşılık derin öğrenme

modelleri, yeterli veri ve hesaplama gücü sağlandığında, bu süreci büyük ölçüde otomatikleştirebilmektedir. Bununla birlikte, yüksek performans genellikle büyük veri kümeleri ve güçlü donanım altyapısı gerektirmektedir. Özellikle GPU destekli sistemler, çok sayıda matris işlemi içeren bu modeller için önemli bir avantaj sağlamaktadır (Gayhardt ve diğerleri, 2024).

Derin öğrenmenin tarihsel gelişimi incelendiğinde, erken dönem sinir ağı çalışmalarının teorik temel oluşturduğu; ancak asıl sıçramanın 2000'li yılların sonrasında gerçekleştiği görülmektedir. Bu dönemde hem veri hacminin artması hem de paralel hesaplama olanaklarının yaygınlaşması, daha derin ve karmaşık ağ yapılarını uygulanabilir hale getirmiştir.

3.2.1. Derin Öğrenme Modelleri

Derin öğrenme ekosistemi, verinin doğasına ve hedeflenen çıktıya göre özelleşmiş çeşitli mimarilere evrilmiştir:

- **Evrışimli Sinir Ağları (CNN):** Özellikle görsel verilerin işlenmesinde, mekansal hiyerarşiyi (kenar, köşe, doku tespiti) koruyarak üstün başarı sağlar.
- **Yinelemeli Sinir Ağları (RNN) ve LSTM/GRU:** Metin veya zaman serisi gibi ardışık verilerde, geçmiş bilgiyi hafızada tutarak zamansal bağımlılıkları modeller.
- **Transformatörler (Transformers):** Günümüzde özellikle doğal dil işleme (NLP) alanında devrim yaratan, dikkat (attention) mekanizmasına dayalı mimarilerdir.
- **Üretken Çekişmeli Ağlar (GAN):** İki ağın (üretici ve ayırt edici) birbiriyle rekabeti üzerinden sentetik ve gerçekçi veri üretimi sağlar.

Son dönemde literatürde, bu mimarilerin hibrit kullanımı (örneğin görüntü açıklaması üretmek için CNN-RNN birleşimi) ve dikkat mekanizmalarının entegrasyonu popülerlik kazanmıştır. Bu hibrit yapılar, finansal piyasaların analizi, biyomedikal görüntüleme ve çok modlu (multimodal) yapay zeka sistemlerinin geliştirilmesinde kritik rol oynamaktadır (Varürer ve Özyayın, 2024).

Bu çalışmada derin öğrenmenin nispeten yeni modellerinden TFT modeli kullanılmış olup bir sonraki bölümde ayrıntılı bir şekilde açıklanmıştır.

3.2.2. Temporal Fusion Transformer(TFT)

Temporal Fusion Transformer (TFT), çok değişkenli zaman serilerinin öngörüsünde yönelik geliştirilmiş hem esnek hem de yorumlanabilir bir derin

öğrenme mimarisidir. Lim ve arkadaşları (2021) tarafından önerilen bu yapı, klasik zaman serisi yöntemlerinin sınırlı kaldığı durumlarda daha kapsamlı bir modelleme imkânı sunmaktadır. Özellikle kısa ve uzun dönemli bağımlılıkların aynı çerçevede ele alınabilmesi ve giriş değişkenlerinin etkisinin analiz edilebilmesi, modeli öne çıkaran özellikler arasındadır. Finansal öngörü, enerji talep projeksiyonları ve sağlık verilerinin analizi gibi karmaşık uygulamalarda yüksek doğruluk sağlaması bu yapının yaygınlaşmasına katkı sağlamıştır (Lim vd., 2021).

TFT mimarisi, LSTM tabanlı dizisel öğrenme yaklaşımını dikkat (attention) mekanizmaları ile bütünleştirir. Bu bütünleşik yapı sayesinde model, yalnızca zamansal ilişkileri değil, değişkenler arası etkileşimleri de öğrenebilmektedir. Mimari genel olarak üç temel bileşenden oluşmaktadır: değişken seçim katmanları, zaman serisi kodlayıcı yapısı ve çok başlıklı dikkat mekanizması.

3.2.2.1. Değişken Seçim Mekanizması

Modelin ayırt edici yönlerinden biri, her zaman adımı için giriş değişkenlerini ayrı ayrı değerlendirebilmesidir. Bu amaçla kullanılan değişken seçim ağı, öngörü üzerinde daha belirleyici olan değişkenleri ön plana çıkarırken daha az etkili olanların ağırlığını azaltmaktadır. Değişken önem düzeyleri softmax normalizasyonu aracılığıyla hesaplanmaktadır:

$$a_i^t = \frac{\exp(e_i^t)}{\sum_j \exp(e_j^t)}$$

Burada a_i^t , t anındaki i'inci değişkenin görece önem skorunu; e_i^t ise ilgili değişkenin model içindeki aktivasyon değerini ifade etmektedir. Bu yapı sayesinde model, hangi girdilerin öngörü sürecine daha fazla katkı sağladığını açık biçimde ortaya koyabilmektedir.

3.2.2.2. Zaman Serisi Kodlayıcı Yapısı

TFT'de geçmiş gözlemleri temsil etmek amacıyla LSTM tabanlı bir kodlayıcı, gelecek öngörülerini üretmek için ise yine LSTM temelli bir çözücü (decoder) kullanılmaktadır. LSTM hücreleri; unutma kapısı (f_t), giriş kapısı (i_t), aday hücre durumu (\tilde{C}_t), hücre durumu (C_t) ve çıktı kapısı (O_t) bileşenlerinden oluşur. Bu yapı aşağıdaki standart denklemlerle ifade edilmektedir:

$$\begin{aligned} f_t &= \sigma(W_f \cdot |h_{t-1}, x_t| + b_f) \\ i_t &= \sigma(W_i \cdot |h_{t-1}, x_t| + b_i) \\ \tilde{C}_t &= \tanh(W_c \cdot |h_{t-1}, x_t| + b_c) \end{aligned}$$

$$\begin{aligned}
C_t &= f_t \times C_{t-1} + i_t \times \tilde{C}_t \\
O_t &= \sigma(W_o \cdot |h_{t-1}, x_t| + b_o) \\
h_t &= O_t \times \tanh(C_t)
\end{aligned}$$

Bu mekanizma sayesinde hem geçmiş bilgi korunmakta hem de yeni gelen veri kontrollü biçimde modele dâhil edilmektedir. Sonuç olarak, zaman boyutundaki kısa ve uzun vadeli ilişkiler aynı çatı altında temsil edilebilmektedir.

3.2.2.3. Dikkat (Attention) Mekanizması

Modelin üçüncü bileşeni, Transformer mimarisinden uyarlanan çok başlıklı dikkat yapısıdır. Bu mekanizma, zaman serisi içerisindeki hangi zaman noktalarının öngörü açısından daha kritik olduğunu belirleyebilmek için kullanılmaktadır. Tek başlıklı dikkat hesaplaması şu şekilde ifade edilir:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V$$

Burada Q sorgu (query), K anahtar (key), V değer (value) vektörlerini; d_k ise anahtar vektörünün boyutunu temsil etmektedir.

Çok başlıklı yapı ise aşağıdaki biçimde tanımlanmaktadır:

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_h)W^O$$

Her bir başlık:

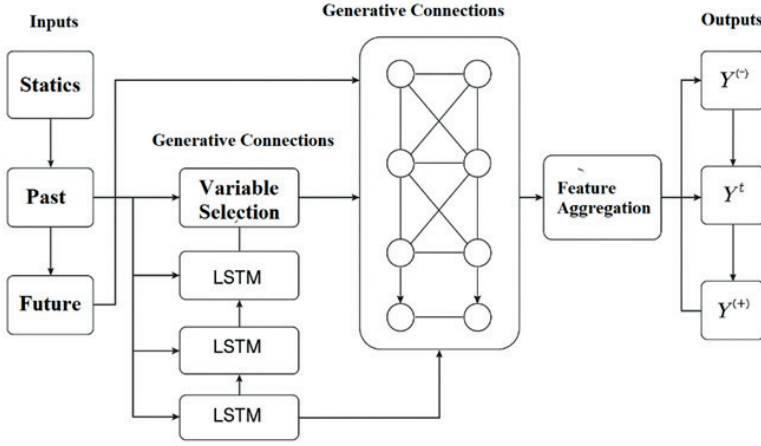
$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V)$$

şeklinde hesaplanmaktadır.

Dikkat çıktısı, artık bağlantılar (residual connections) ve katman normalizasyonu ile birlikte işlenir:

$$Output = LayerNorm(x + AttentionOutput)$$

Bu bütünleşik yapı, derin ağlarda gradyan akışını düzenleyerek öğrenme sürecinin daha kararlı ilerlemesini sağlamaktadır.



Şekil 2. TFT çalışma mekanizması (Varüver vd., 2025)

TFT'nin önemli avantajlarından biri, yalnızca öngörü üretmekle kalmayıp hangi değişkenlerin ve hangi zaman aralıklarının daha etkili olduğunu da gösterebilmesidir. Model tarafından üretilen değişken seçim skorları ve dikkat ağırlıkları, öngörü sürecinin şeffaflığını artırmakta ve karar destek sistemleri açısından anlamlı çıktılar sunmaktadır.

Genel olarak değerlendirildiğinde TFT, çok değişkenli zaman serilerinde kısa ve uzun dönemli ilişkileri eş zamanlı biçimde ele alabilen, değişken etkilerini analiz edebilen ve yorumlanabilir sonuçlar üretebilen gelişmiş bir derin öğrenme mimarisidir. Özellikle karmaşık veri yapılarında hem performans hem de açıklanabilirlik açısından güçlü bir alternatif sunmaktadır (Lim vd., 2021).

Tüm yapay zeka modellerinde model oluşturulup uygulandıktan sonra, modelin başarısını gösteren çeşitli istatistiksel ölçütler kullanılmaktadır.

3.3. Başarı ölçüm metrikleri

Zaman serisi öngörü modellerinin performansını değerlendirmek hem modelin genelleme yeteneğini hem de öngörü doğruluğunu nicel olarak ortaya koymak açısından önemlidir. Bu değerlendirme için kullanılan metrikler, model çıktıları ile gerçek gözlemler arasındaki farkların çeşitli biçimlerde ölçülmesinden oluşur. Bu çalışmada temel performans ölçütü olarak Kök Ortalama Kare Hata (Root Mean Squared Error, RMSE) kullanılmıştır. RMSE, her bir öngörünün gerçek değerle arasındaki farkın karelerinin ortalamasının karekökü olarak tanımlanır ve öngörü hatalarının ortalama büyüklüğünü ifade eder. Matematiksel olarak, n gözlem için RMSE,

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - \widehat{Y}_i)^2}$$

şeklinde hesaplanır; burada Y_i gerçek değeri, \widehat{Y}_i ise model tarafından öngörülen değeri göstermektedir. RMSE, hataların kareleri üzerinden hesaplandığı için büyük hatalara daha yüksek ceza verir ve bu nedenle özellikle büyük sapmaların kritik olduğu uygulamalarda tercih edilir. Ayrıca bu metrik, öngörü hatalarının orijinal veri birimi ile ortaya konulmasına olanak tanır, bu da yorumlanabilirliği artırır.

Alternatif metrikler arasında Ortalama Mutlak Hata (Mean Absolute Error, MAE) ve Ortalama Mutlak Yüzdesele Hata (Mean Absolute Percentage Error, MAPE) gibi ölçütler de sıklıkla kullanılmaktadır. MAE, öngörülen ve gerçek değerler arasındaki mutlak farkların ortalamasını alarak hata büyüklüğünü doğrudan ifade ederken, MAPE hatayı yüzde olarak ifade ederek farklı ölçeklerdeki serilerin karşılaştırılmasına olanak sağlar. Ancak MAPE gibi yüzdesel metriklerin, gerçek değerlerin sıfıra yakın olduğu durumlarda büyük veya tanımsız sonuçlar üretebildiği belirtilmiştir (Hyndman ve Koehler, 2006).

Bu çalışmada RMSE'nin tercih edilmesinin temel nedeni, modelin öngörü hatalarının büyüklüğünü tutarlı bir şekilde değerlendirmesi ve özellikle yüksek değerli ekonomik göstergeler söz konusu olduğunda ölçekte doğrudan interpretasyon sağlamasıdır. Ayrıca RMSE'nin yaygın kullanımı, diğer zaman serisi çalışmalarındaki performans karşılaştırmalarına olanak tanıyarak modeller arası objektif değerlendirme yapılmasına yardımcı olur.


4. Bulgular

Veri ön işleme aşamasında zaman serilerinin varyansını stabilize etmek ve aşırı uç değerlerin etkisini azaltmak amacıyla logaritmik dönüşüm uygulanmıştır. Ayrıca eksik gözlemler kontrol edilmiş ve model eğitiminde kullanılmadan önce veri seti kronolojik sıraya uygun biçimde eğitim ve doğrulama alt kümelerine ayrılmıştır. Zaman serisi yapısının korunması amacıyla rastgele karıştırma (randomization) yapılmamıştır.

Öngörü sürecinde, çok değişkenli zaman serisi problemleri için geliştirilen Temporal Fusion Transformer (TFT) mimarisi kullanılmıştır. TFT modeli; LSTM tabanlı encoder-decoder yapısını, dikkat (attention) mekanizması ve değişken seçim katmanları ile birleştirerek hem kısa vadeli hem de uzun vadeli bağımlılıkları eş zamanlı olarak modelleyebilmektedir. Model yapısında geçmiş gözlemleri temsil eden encoder bölümü ile geleceğe yönelik öngörü ufkunu temsil eden decoder bölümü birlikte çalışmaktadır. Maksimum geçmiş uzunluğu

(encoder length) ve öngörü ufku (prediction length) hiperparametreleri belirlenerek model optimize edilmiştir.

Model eğitimi sırasında erken durdurma (early stopping) mekanizması kullanılarak aşırı öğrenme (overfitting) riski azaltılmıştır. Hiperparametre optimizasyonu sonucunda en uygun öğrenme oranı ve ağ mimarisi belirlenmiştir. Model performansının değerlendirilmesinde Kök Ortalama Kare Hata (RMSE) temel hata metriği olarak kullanılmıştır. Ayrıca modelin algoritması için Phyton programının Keras kütüphanesinden yararlanılmıştır.




Şekil 3. TFT model sonuçları

Yukarıdaki şekil 3'te TFT modelinin sonuçlarının son 6 verideki kısmı çizgilerin yakınlığının daha iyi görülebilmesi için kesilip alınarak gösterilmiştir. Çok değişkenli zaman serisi yapısına uygun olarak kurgulanan model, geçmiş gözlemler ile eş zamanlı ekonomik göstergeleri birlikte değerlendirerek ileriye dönük öngörü üretmiştir. Model performansı, logaritmik dönüşüm uygulanmış veri üzerinden eğitildikten sonra gerçek ölçeğe geri dönüştürülerek hesaplanan RMSE değeri ile ölçülmüştür. Bu kurulan TFT modeli için elde edilen RMSE değeri 36,01 olarak bulunmuştur. Elde edilen 36,01 düzeyindeki RMSE, endeksin binler seviyesine ulaştığı göz önüne alındığında oldukça düşük bir öngörü hatasına işaret etmektedir. Bu durum, modelin hem trend bileşenini hem de değişkenler arası doğrusal olmayan ilişkileri başarılı biçimde yakalayabildiğini göstermektedir.

Temporal Fusion Transformer (TFT) modelinin en önemli avantajlarından biri, yüksek öngörü performansının yanı sıra yorumlanabilirlik sağlamasıdır. Geleneksel derin öğrenme modelleri genellikle “kara kutu” (black-box) yapılar olarak değerlendirilirken, TFT mimarisi değişken seçim katmanları (variable selection networks) ve dikkat (attention) mekanizması sayesinde hangi

değişkenlerin öngörü sürecine ne ölçüde katkı sağladığını analiz etmeye imkân tanımaktadır. Aşağıdaki şekilde değişken önem analizinin sonuçları verilmiştir.



Şekil 4. TFT modeli değişken önem analizi

Modelin sunduğu değişken önem analizine göre, inşaat maliyet endeksinin öngörüsünde en yüksek katkıyı %20 oranı ile inşaat m^2 ve imalat sanayi yani sanayi üretim endeksi değişkeni sağlamıştır. Bu bulgu, sektördeki fiziksel üretim ve metrekare bazlı maliyet hareketlerinin doğrudan maliyet endeksi üzerinde belirleyici olduğunu ortaya koymaktadır. Aynı zamanda, inşaat sektörünün girdi yapısının sanayi üretimi ile güçlü bir bağlantı içinde olduğunu ve maliyet dinamiklerinin reel üretim koşullarından önemli ölçüde etkilendiğini düşündürmektedir.

Buna karşılık, konut satış endeksi değişkeninin katkısı %12 düzeyinde kalmıştır. Bu durum, talep yönlü göstergelerin maliyet oluşumuna dolaylı etki ettiğini, ancak maliyet dinamiklerinin daha çok arz ve üretim temelli faktörlerle şekillendiğini göstermektedir.

Model içinde gecikmeli inşaat maliyet endeksi değişkeninin katkısının %45 seviyelerinde olması ise, endeksin büyük ölçüde mevcut makroekonomik koşullar ve sektörel göstergeler tarafından açıklandığını fakat aynı zamanda geçmiş değerlerin tek başına güçlü bir açıklayıcı olduğunu da ortaya koymaktadır.

Genel olarak değerlendirildiğinde, Temporal Fusion Transformer modeli hem düşük öngörü hatası hem de değişken bazlı açıklanabilirlik sağlaması açısından güçlü bir performans sergilemiştir. Attention mekanizması sayesinde model, farklı zaman dilimlerinde hangi değişkenlerin daha belirleyici olduğunu dinamik biçimde ağırlıklandırabilmiştir. Bu özellik, özellikle makroekonomik ve sektörel zaman serilerinde yapısal değişimlerin bulunduğu dönemlerde önemli bir avantaj sunmaktadır.

Sonuç olarak, elde edilen bulgular inşaat maliyet endeksinin öngörüsünde üretim ve arz yönlü göstergelerin baskın rol oynadığını göstermekte; Transformer tabanlı derin öğrenme yaklaşımlarının, geleneksel tekrarlayan ağ mimarilerine kıyasla daha esnek ve açıklanabilir bir yapı sunduğunu ortaya koymaktadır. Bu çerçevede, politika yapıcılar ve sektör analistleri açısından TFT modeli, maliyet baskılarının erken tespiti ve ileriye dönük projeksiyonların oluşturulması için etkili bir araç niteliği taşımaktadır.

5. Sonuç ve Öneriler

İnşaat sektörü, ekonomik büyüme, istihdam, altyapı yatırımları ve konut piyasası üzerindeki doğrudan etkileri nedeniyle makroekonomik yapı içerisinde stratejik bir konuma sahiptir. Özellikle son yıllarda küresel tedarik zinciri sorunları, emtia fiyatlarındaki artış, enerji maliyetlerindeki dalgalanmalar ve döviz kuru oynaklığı, inşaat maliyetlerinde belirgin artışlara ve volatiliteye yol açmıştır. Bu durum, İnşaat Maliyet Endeksi'nin (İME) doğru ve güvenilir biçimde öngörülmesini hem kamu otoriteleri hem de özel sektör yatırımcıları açısından kritik hale getirmiştir.

Geleneksel zaman serisi modelleri, doğrusal varsayımlara dayalı yapıları nedeniyle karmaşık ve doğrusal olmayan ilişkileri yeterince modelleyememektedir. Buna karşılık, yapay zekâ ve derin öğrenme tabanlı yöntemler, çok değişkenli ve yüksek boyutlu veri yapıları içerisinde yer alan karmaşık örüntüleri öğrenme kapasitesine sahiptir. Bu bağlamda çalışmada, çok değişkenli zaman serisi öngörüsü için geliştirilen Temporal Fusion Transformer (TFT) mimarisi kullanılmıştır.

Modelleme sürecinde yalnızca geçmiş İME değerleri değil, aynı zamanda maliyet dinamiklerini etkileyebileceği düşünülen makroekonomik göstergeler de bağımsız değişken olarak dahil edilmiştir. Veri ön işleme aşamasında logaritmik dönüşüm uygulanarak varyans stabilizasyonu sağlanmış, model eğitimi sırasında erken durdurma mekanizması ile aşırı öğrenme riski azaltılmıştır. Performans değerlendirmesinde temel hata metriği olarak Kök Ortalama Kare Hata (RMSE) kullanılmıştır. TFT modeli için RMSE değeri 36.01 olarak bulunmuştur.

Elde edilen bulgular, TFT modelinin hem kısa vadeli öngörülerde hem de tüm dönem boyunca gerçekleştirilen bir-adım-ileri öngörülerde güçlü bir performans sergilediğini göstermektedir. Model, genel trendi başarılı biçimde yakalamış ve yüksek oynaklık dönemlerinde dahi makul sapmalarla öngörü üretmiştir. RMSE değerlerinin düşük seviyede gerçekleşmesi, modelin genelleme kapasitesinin yüksek olduğunu ve aşırı öğrenme problemi göstermediğini ortaya koymaktadır.

Çalışmanın önemli katkılarından biri de deęişken önem analizidir. TFT modelinin sunduęu deęişken seçim mekanizması sayesinde, inşaat maliyetlerini etkileyen göstergelerin görelı katkıları nicel olarak analiz edilmiştir. Bu analiz, modelin yalnızca istatistiksel doğruluęunu deęil, aynı zamanda ekonomik anlamlılıęını da deęerlendirmeye imkân tanımaktadır. Elde edilen önem skorları, maliyet dinamiklerinde belirli makroekonomik deęişkenlerin daha baskın rol oynadıęını ortaya koymuş ve sektörel politika tasarımlarına ışık tutabilecek bulgular sunmuştur.

Genel olarak deęerlendirildięinde, derin öğrenme tabanlı modellerin inşaat maliyet öngörüsünde geleneksel yöntemlere kıyasla daha esnek ve yüksek performanslı sonuçlar ürettięi görülmektedir. Özellikle çok deęişkenli yapıların ve doğrusal olmayan ilişkilerin yoğun olduęu ekonomik serilerde, Transformer tabanlı mimariler güçlü bir alternatif olarak öne çıkmaktadır.

Bu bulgular doğrultusunda, inşaat maliyetlerinin izlenmesi ve geleceęe yönelik projeksiyonların oluşturulmasında yapay zekâ tabanlı öngörü modellerinin aktif olarak kullanılması göz önünde bulundurulmalıdır. Akademik açıdan bakıldığında, gelecekte yapılacak çalışmalarda farklı derin öğrenme mimarilerinin karşılaştırmalı analizleri gerçekleştirilebilir ve modele küresel emtia fiyatları, faiz oranları veya jeopolitik risk göstergeleri gibi ek deęişkenler dahil edilerek öngörü doğruluęu daha da artırılabilir. Ayrıca uzun vadeli çok adımlı öngörü performansının farklı kayıp fonksiyonları ile test edilmesi, modelin ileri dönem öngörü kapasitesine ilişkin daha kapsamlı sonuçlar sağlayacaktır.

6. Kaynakça

- Aslam, B., Maqsoom, A., Inam, H., Basharat, M. u., & Ullah, F. (2023). Forecasting Construction Cost Index through Artificial Intelligence. *Societies*, 13(10), 219. <https://doi.org/10.3390/soc13100219>
- Aydınlı, S. (2022). Time series analysis of building construction cost index in Türkiye. *Journal of Construction Engineering, Management & Innovation (Online)*, 5(4), 218 - 227. doi.org/10.31462/jcemi.2022.04218227
- Bui Anh Tu, Ngo Tri Thu. "Predicting Construction Price Index Using Deep Learning Method" *International Research Journal of Economics and Management Studies*, Vol. 3, No. 4, pp. 117-124, 2024.
- Gayhardt, L., Garimella, A., Salgado, S., Gilley, S., Franks, L., Brizi, M., . . . Lu, P. (2024, 01 19). Deep learning vs. machine learning in Azure Machine Learning. Microsoft Learn: <https://learn.microsoft.com/en-us/azure/machine-learning/concept-deep-learning-vs-machine-learning?view=azureml-api-2> adresinden alındı.
- Güney, E. N. (2022, Mart). Derin öğrenmede istatistiksel yöntemlerle hisse senedi fiyatı öngörüsü. Yüksek Lisans Tezi. Isparta: Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü.
- Lim, B., Arik, S. Ö., Loe, N., & Pfister, T. (2021). Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4), 1748–1764.
- McCulloch, W. S., & Pitts, W. (1943). A Logical Calculus of Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, 115-133
- Öztürk, K., & Şahin, M. E. (2018). Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. *Takvim-i Vekayi*, 25-36
- Tüz, Ö. & Ebese, Ş. (2023). Optimizing Holt-Winters Exponential Smoothing Parameters for Construction Cost Index Forecasting with PSO and Walk-Forward Cross-Validation, *Kent Akademisi Dergisi*, 16(4):2422-2439. <https://doi.org/10.35674/kent.1352488>
- Üntez, A. (2022, Ocak). Gümüş/ons paritesi üzerine derin öğrenme ile finansal tahmin modellemesi geliştirilmesi. Yüksek Lisans Tezi. Sakarya Üniversitesi Fen Bilimleri Enstitüsü.
- Varürer, İ., & Özaydın, Ö. (2024). Silver price prediction with BiLSTM deep learning model. In Ö. Alpu (Ed.), *Current topics in statistics* (pp. 123–145). Eğitim Publishing House.
- Varürer, İ., Özaydın, Ö., & Çemrek, F. (2025). Bitcoin price prediction with ARIMAX and deep learning models. *EstuScience - Se*, 26(4), 426–444. <https://doi.org/10.18038/estubtda.1736511>
- Wang, J., Qu, Z., Lee, C. Y., & Skitmore, M. (2025). Highway construction cost index forecasting: a hybrid VMD–LSTM–GRU method. *Construction Management and Economics*, 43(10), 849–863. <https://doi.org/10.1080/01446193.2025.2525871>