

Finansal Zaman Serisi Tahmininde LSTM ve TCN Modellerinin Karşılaştırılması: BIST 100 Endeksi Üzerine Bir Uygulama

Mehmet Sandal¹

Özet

Hisse senedi piyasaları, doğrusal olmayan ve karmaşık yapısı nedeniyle yatırımcılar için tahmin edilmesi güç bir alan olmayı sürdürmektedir. Finansal zaman serilerinin ani fiyat hareketlerine açık olması ve karmaşık örüntülere sahip olması, istatistiksel yöntemlerin tahmin performanslarını da etkilemektedir. Bu nedenle finansal riskleri minimize ederek yatırım getirilerini artırmak ve tutarlı tahminlerde bulunmak için gelişmiş modellerin kullanılması oldukça önemli hale gelmiştir.

Bu çalışmanın amacı, doğrusal olmayan ve uzun dönemli bağımlılıklar içeren sıralı verilerin analizinde derin öğrenme yöntemlerinin performanslarını karşılaştırmaktır. Bu amaçla 2015-2025 yılları arasındaki BIST 100 endeksinin günlük kapanış fiyatları için Uzun-Kısa Süreli Bellek (LSTM) ve Zamansal Evrişimli Ağ (TCN) mimarileri tasarlanmıştır. Çalışmada Hyperband algoritması ile hiperparametre optimizasyonu gerçekleştirilmiş ve modellerin tahmin performansları RMSE, MAE ve MAPE hata ölçütleri üzerinden değerlendirilmiştir. Elde edilen bulgular, her iki modelin de BIST 100 endeksinin uzun vadeli bağımlılıklarını başarılı biçimde yakalayabildiğini göstermektedir. Ancak hata metrikleri incelendiğinde TCN mimarisine göre elde edilen sonuçların LSTM'ye göre daha düşük hata değerleri ürettiği belirlenmiştir. Özellikle ani piyasa değişimlerine ve trend dönüşlerine TCN mimarisinin daha iyi uyum sağladığı ve daha isabetli şekilde tahmin ettiği saptanmıştır. Bu bulgular, TCN mimarisinin finansal zaman serisi tahmininde doğrusal olmayan dinamikleri modellemede güçlü ve yenilikçi bir alternatif sunduğunu göstermektedir.

1 Dr. Öğr. Üyesi, Manisa Celal Bayar Üniversitesi, mehmet.sandal@cbu.edu.tr,
<https://orcid.org/0000-0001-7396-0801>

1. Giriş

Finans piyasaları, çağdaş ekonomilerin en önemli bileşenlerinden biri olup küresel ekonomik düzenin işleyişinde belirleyici bir rol oynamaktadır. Ancak bu piyasalar, makroekonomik olaylara ve doğrusal olmayan ilişkilere bağlı oldukları için oldukça karmaşık bir yapıya sahiptir. Bu nedenle, likidite problemleri, ani fiyat dalgalanmaları veya piyasa çöküşleri gibi durumlarda sermayenin doğru yönlendirilmesi veya portföy yönetiminin doğru uygulanması için finansal riskleri tahmin etmek son derece önemli hale gelmektedir (Fan, Liang, & Hu, 2025).

Ekonomi ve finans alanları başta olmak üzere piyasaların genel eğiliminin belirlenmesinde ve tahmin edilmesinde zaman serisi modellerinden yararlanılmaktadır. Geçmiş dönemlere ait veriler dikkate alınarak gelecekteki piyasa hareketliliği ve ekonomik göstergelere ilişkin örüntüler, zaman serisi analizleri ile ortaya çıkarılabilmektedir (Yi, 2024). Bu nedenle finansal piyasalarda etkin modelleme yöntemlerinin geliştirilmesi ve uygulanması önemli bir rol oynamaktadır (Fan, Liang, & Hu, 2025).

Finansal verilerin analizinde sıklıkla ARIMA ve GARCH gibi zaman serisi modellerinden yararlanılır. Bu alanda yapılan çalışmalar incelendiğinde Şangay Bileşik Endeksi (Haijian ve Qianqian, 2017; Zhang, 2023), Borsa İstanbul fiyat endeksi (Mashadihasanlı, 2022), NASDAQ 100 endeksi (Yi, 2024) gibi farklı borsa endeks verilerinin tahmin edilmesinde ARIMA modeli sıklıkla kullanılmaktadır. Ayrıca Almasarweh ve Wadi (2018), Alhawtmeh (2022), Rawlin ve Pakalapati (2022), Sudipa vd. (2023), Zíková ve Veselá (2023), Yeung (2024) ise yaptıkları çalışmalarda, farklı borsalarda işlem gören çeşitli hisse senedi fiyatlarını tahmin etmek için ARIMA ve GARCH modellerinden yararlanmışlardır. Finansal verileri modellemek ve analiz etmek için kullanılan ARIMA ve GARCH gibi istatistiksel yöntemler, durağanlık ve doğrusallık gibi varsayımlara dayanmaktadır. Ancak piyasalardaki makroekonomik faktörlere bağlı olarak yaşanan dalgalanmalar, veri miktarının oldukça yüksek olması ve piyasaların doğrusal olmayan yapısı nedeniyle genellikle bu yöntemlerin etkinliğini azaltmaktadır (Zhang, Sjarif & Ibrahim, 2024; Fan, Liang, & Hu, 2025).

Son yıllarda yapay zekâ alanındaki ilerlemeler ve yüksek boyutlu veri yapılarının yaygınlaşması, finansal zaman serisi tahmininde derin öğrenme yöntemlerinin giderek yaygınlaşmasına yol açmıştır (Zhang, Zhang & Hu, 2025). Derin öğrenme yöntemleri, öğrenme süreçleri ve modelleme yetenekleri sayesinde finansal verilerin modellenmesinde ve gizli yapıları öğrenmede klasik yöntemlere göre avantajlı konumda yer almaktadır (Selvin vd., 2017).

Bu modellerde, sinir ağlarının insan beyninin örnek alınan öğrenme modeli yapısı kullanılarak girdiler belirli ağırlıklara göre katmanlarda işlenerek veri setine ilişkin en iyi tahmin sonucunun elde edilmesi amaçlanmaktadır. Burada sinir ağının kendi kendine öğrenme mekanizması sayesinde ağırlıklar ayarlanarak en iyi tahmine ulaşabilmek için uygun kalıplar belirlenmeye çalışılmaktadır (Ingle & Deshmukh, 2021).

Bu alanda yapılan çalışmalardan bazıları ise Yang, Gong ve Yang (2017) tarafından Şanghay bileşik endeksi, Eapen, Bein ve Verma (2019) tarafından S&P 500 endeksi, Nikou, Mansourfar ve Bagherzadeh (2019) çalışmalarında iShares MSCI Birleşik Krallık borsa yatırım fonu, Rezaei, Faaljou ve Mansourfar (2021) çalışmalarında S&P500, Dow Jones, DAX ve Nikkei225 endeks değerlerini, Mukherjee vd. (2023) çalışmasında Hindistan Borsası NSE Nifty endeksini Al-Khasawneh vd. (2025) ise Pakistan Menkul Kıymetler Borsası endeks değerini tahmin etmek için derin öğrenme yöntemlerini kullanmışlardır. Akbulut ve Adem (2023), Çelik (2024), Varürer, Özaydın ve Çemrek (2025) çalışmalarında BIST 100 endeksini tahmin etmek için derin öğrenme yöntemlerinden yararlanmışlardır.

Bu çalışmada, BIST 100 endeks değerindeki uzun dönemli bağımlılıklar dikkate alınarak iki farklı derin öğrenme mimarisinin tahmin performansları karşılaştırılmıştır. Çalışmanın ikinci bölümünde derin öğrenme modelleri açıklanmış, üçüncü bölümde veri setine ilişkin bilgilere yer verilmiştir. Dördüncü bölümde bulgular aktarılmış ve son bölümde ise elde edilen sonuçlar tartışılmıştır.

2. Derin Öğrenme Yöntemleri

Derin öğrenme, insan beyninin öğrenme biçimini çok katmanlı yapay sinir ağları aracılığıyla taklit eden bir makine öğrenmesi yaklaşımıdır (Şişmanoğlu vd., 2020; Akbulut & Adem, 2023; Demirci & Karaatlı, 2023). Bir veya daha fazla girdiye sahip, verileri işlemek için çok sayıda gizli katman kullanan ve sonuçta bir veya daha fazla çıktı üreten gelişmiş bir bilgisayar tekniğidir (Arslankaya & Toprak, 2021; Çoban & Hayat, 2023). Bu yapıda, birbirine bağlı nöronlar aracılığıyla verilerden örüntüler öğrenilmekte ve katmanlararası ağırlıkların optimizasyonu sağlanarak aktivasyon fonksiyonları aracılığıyla karmaşık karar süreçleri modellenmektedir (Odabaşı & Toklu, 2023).

Geleneksel makine öğrenmesi algoritmalarının aksine derin öğrenme, büyük boyutlardaki verileri manuel bir özellik çıkarımına ihtiyaç duymadan doğrudan işleyebilmekte ve kendi kendine özellik temsillerini öğrenebilmektedir (Şişmanoğlu vd., 2020). İçerisindeki gizli katmanlar sayesinde karmaşık ve doğrusal olmayan verilerdeki ilişkileri yakalayabilme kabiliyeti nedeniyle zaman

serisi analizleri, regresyon ve sınıflandırma problemleri, dil ve görüntü işleme araştırmaları, enerji ve çevre konuları başta olmak üzere pek çok alanda derin öğrenme algoritmalarından sıklıkla yararlanılmaktadır (Kara, 2019; Arslankaya ve Toprak, 2021).

Derin öğrenme alanında, farklı problem türlerine ve veri yapılarının özelliklerine göre tasarlanmış çeşitli mimariler geliştirilmiştir. Bu mimarilerin başında Evrişimli Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN), Uzun-Kısa Süreli Bellek (LSTM), Kapılı Tekrarlayan Birim (GRU), Üretken Çekişmeli Ağlar (GAN) ve Derin İnanç Ağları (DBN) gelmektedir. Görüntü verilerinde sıklıkla Evrişimli Sinir Ağları (CNN) kullanılırken zaman bağımlı verilerde ise Tekrarlayan Sinir Ağları (RNN) ile Uzun-Kısa Süreli Bellek (LSTM) ve Geçitli Tekrarlayan Ünite (GRU) yapıları öne çıkmaktadır. Sentetik veri üretiminde Üretken Çekişmeli Ağlar (GAN) ve olasılıksal modellemelerde ise DBN mimarileri tercih edilmektedir.

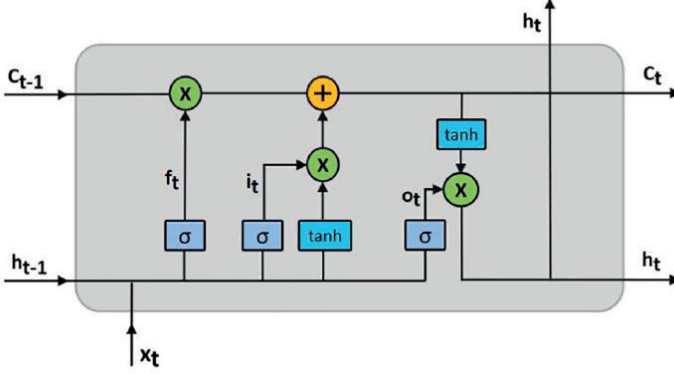
Sıralı verilerin modellenmesinde genellikle RNN algoritmaları kullanılmaktadır. Ancak burada girdi katmanında yer alan her bir veri, bir önceki çıktının değerine göre yinelenmeli olarak sürdürülmektedir. Dolayısıyla RNN mimarisinde zaman adımları arttıkça uzun veri dizilerinin öğrenme aşamasında önemli bilgilerin unutulması (gradyan kaybolması) problemi ile karşılaşmaktadır. Bu nedenle gerekli olan bilgilere önem veren modellere ihtiyaç duyulmaktadır. Bu çalışmada da sıralı verilerin modellenmesinde gradyan kaybolması problemini çözmek için Uzun-Kısa Süreli Bellek (LSTM) ve Zamansal Evrişimli Ağ (Temporal Convolutional Network (TCN)) mimarileri ele alınmıştır.

2.1. Uzun-Kısa Süreli Bellek (LSTM)

Tekrarlayan Sinir Ağları (RNN) algoritmasının gelişmiş bir modeli Uzun-Kısa Süreli Bellek (LSTM) yapısıdır (Sonkavde vd., 2023). LSTM, sıralı verilerin uzun dönemli bağımlılıklarını modellemek ve RNN mimarisindeki öğrenme sürecinin gradyan kaybolması problemini çözmek için Hochreiter ve Schmidhuber (1997) tarafından önerilen bir öğrenme modelidir (Zeroual vd., 2020; Sonkavde vd., 2023).

LSTM mimarisinde, bilgi akışını kontrol eden kapı mekanizmaları aracılığıyla öğrenilen bilgilerden saklanması gereken veya ihtiyaç duyulmayan bilgilerin hangileri olduğuna karar verilebilmektedir. Böylece gradyan problemi ortadan kaldırılarak önemli bilgiler uzun süre saklanabilmektedir. Bu nedenle LSTM mimarisi ile bilgilerin uzun dönemler boyunca öğrenilebilmesi ve önemli bilgilerin hafızada tutulması sağlanmaktadır (Sonkavde vd., 2023; Li, 2024).

Bir LSTM mimarisinde bilgi akışını kontrol eden “bellek hücresi” ve bilgi akışını düzenlemek için unutmaya, giriş ve çıkış olmak üzere üç temel kapı mekanizması yer almaktadır. Bu yapı için bellek hücresi ve kapı mekanizmaları Şekil 1’de gösterilmektedir.



Şekil 1: LSTM yapısı (Kaynak: Rezaei, Faaljou ve Mansourfar (2021))

Unutma Kapısı: Bu kapıda, hangi bilgilerin silineceğine ve hangi bilgilerin saklanacağına karar verilmektedir. Bir sonraki katmana aktarılacak bilgilerin hangileri olduğu bu adımda belirlenmektedir. Burada Eşitlik 1’de verilen f_t fonksiyonu kullanılır:

$$f_t = \sigma(W_f \times [h_{t-1}, X_t] + b_f) \quad (1)$$

Bu fonksiyon ile giriş değeri X_t ve önceki gizil durum h_{t-1} olmak üzere bu değerler giriş bilgileri olarak alınarak ağırlık parametreleri, eğim parametreleri ve sigmoid fonksiyonu kullanılarak 0 ve 1’lerden oluşan bir vektör elde edilir. Böylece hücre değerleri 0’a yaklaştıkça unutulması ve 1’e yaklaştıkça saklanması gerektiğine karar verilir (Ghosh vd., 2019; Zeroual vd., 2020; Dehghani vd., 2023).

Ø Giriş Kapısı: Bu kapıda, hücreye hangi yeni bilgilerin ekleneceğine ve hangi değerlerin güncelleneceğine karar verilmektedir. Bu amaçla Eşitlik 2 ve Eşitlik 3’te verilen fonksiyonlardan yararlanılmaktadır:

$$i_t = \sigma(W_i \times [h_{t-1}, X_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \times [h_{t-1}, X_t] + b_c) \quad (3)$$

$$C_t = (C_{t-1} * f_t + i_t * \tilde{C}_t) \quad (4)$$

İlk olarak i_t fonksiyonu ile bilgiler güncellenmektedir. Ardından \tanh aktivasyon fonksiyonu kullanılarak Eşitlik 4'te verilen aday değerler elde edilmektedir. Bu bilgiler birleştirilerek hücreye aktarılacak yeni bilgilere karar verilmektedir (Ghosh vd., 2019; Zeroual vd., 2020; Rezaei, Faaljou ve Mansourfar, 2021; Dehghani vd., 2023).

Çıkış Kapısı: Bu kapıda ise bir sonraki gizil durumun ne olacağına karar verilmektedir. Bir sigmoid fonksiyonu ile hücre durumu \tanh fonksiyonundan geçirilip çıktı değerleriyle çarpılarak yalnızca karar verilen değerlerin hücre çıktısı olarak üretilmesi sağlanır. Bu aşamadaki işlemler için Eşitlik 5'te verilen fonksiyon kullanılmaktadır:

$$o_t = \sigma(W_o \times [h_{t-1}, X_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

Bu eşitlikler ile bir sonraki zaman hücresinin gizil değeri elde edilmektedir. Böylece eğitim değerleri ile LSTM ağından elde edilen değerler arasındaki fark en aza indirgenene kadar bu adımlar tekrarlanmaktadır (Ghosh vd., 2019; Zeroual vd., 2020; Dehghani vd., 2023; Varürer, Özaydın ve Çemrek, 2025).

2.2. Zamansal Evrişimli Ağ (Temporal Convolutional Network (TCN))

Zamansal Evrişimli Ağ (TCN), zaman serisi ve sıralı verileri işlemek için Bai vd. (2018) tarafından tasarlanmış bir evrişimli ağ yapısıdır. Sıralı dizi tahmini için önerilen bu mimaride, her katmanda aynı filtre kullanılarak evrişimler paralel olarak yürütülebilmektedir. Böylece RNN'lerden farklı olarak sonraki zaman adımlarının tahmini için önceki aşamaların tamamlanması beklenmeden paralel bir şekilde gerçekleştirilebilmektedir. Bu durum, eğitim ve tahmin aşamalarındaki hesaplama sürelerini önemli ölçüde azaltmaktadır.

TCN mimarisi; çekirdek boyutu (kernel size), alıcı alan (receptive field) yapısı, genişletme oranı (dilation rate) ve ağ derinliği gibi parametreler aracılığıyla esnek biçimde ayarlanabilmektedir. Bu esneklik, RNN tabanlı modellere kıyasla daha avantajlı bir konum sağlamaktadır. Eğitim sürecinde gradyan akışı daha kararlı olduğu için gradyan kaybolması veya gradyan patlaması problemlerine daha az maruz kalmaktadır (Wang vd., 2019).

TCN mimarisini diğer sinir ağı yapılarından ayıran ve zaman serisi verilerinde etkili olmasını sağlayan çeşitli temel bileşenler mevcuttur. TCN mimarisinin temel bileşenlerinden biri olan nedensel evrişim (causal convolution) yapısı, evrişim işlemini yalnızca geçmiş zaman adımlarını kapsayacak şekilde sınırlandırmaktadır. Bu yapı sayesinde tahmin yalnızca geçmiş gözlemlere dayandırılmakta ve geleceğe ait bilginin modele sızması engellenmektedir. Böylece zaman serisi analizinde kritik öneme sahip olan bilgi sızıntısı problemi ortadan kaldırılmaktadır. Bu yaklaşım, çalışma prensibi bakımından zaman gecikmeli sinir ağlarına benzerlik göstermektedir (Wang vd., 2019; Shi, Ibrahim & Hashim, 2025). Nedensel evrişim katmanlarının sayısının artırılması, modelin alıcı alanını genişleterek uzun dönemli bağımlılıkları kapsama kapasitesini yükseltmektedir. Ancak katman sayısındaki bu artış, model karmaşıklığını yükselterek hesaplama yükünün önemli ölçüde artmasına neden olabilmektedir. Bu sorunu gidermek amacıyla TCN mimarisine genişletilmiş evrişim (dilated convolution) yapısı entegre edilmektedir (Li vd., 2024).

Genişletilmiş evrişim yapısı ise nedensel evrişimin sınırlı alıcı alan problemini aşmak amacıyla geliştirilmiştir (Wang vd., 2019). Genişletilmiş evrişim, çekirdek yapısı içerisinde belirli aralıklar bırakılarak uygulanan bir evrişim türüdür. Bu yapıda, genişletme oranı olarak adlandırılan bir hiperparametre aracılığıyla çekirdek elemanları arasına belirli boşluklar yerleştirilmektedir. Katman sayısı arttıkça bu aralıklar üstel biçimde genişlemekte, buna karşın çekirdek boyutu sabit kalmaktadır. Böylece alıcı alan önemli ölçüde artırılmakta ve modelin daha uzun dönemli bağımlılıkları daha az katman kullanarak öğrenebilmesi mümkün hale gelmektedir (Wang vd., 2019; Shi, Ibrahim & Hashim, 2025).


Diğer mimarilerden farklı olarak TCN mimarisinin evrişimli yapısı, daha geniş etkili alana erişim ve daha hızlı eğitim avantajı sağlamaktadır (He & Zhao, 2019; Li vd., 2024). Ayrıca TCN mimarisi, derin artık bloklar (rezidüel bloklar) ile genişletilmiş evrişim katmanlarını kullanarak geçmiş dönem bilgilerini esnek ve etkin bir şekilde elde edebilmektedir (Wang vd., 2019).

3. Veri Seti ve Yöntem

Bu çalışmada farklı derin öğrenme mimarilerinin finansal zaman serileri üzerindeki tahmin gücünün karşılaştırılması amaçlanmıştır. Bu doğrultuda, BIST 100 endeksinin günlük kapanış fiyatları TCN ve LSTM mimarileri ile modellenerek tahmin performansları değerlendirilmiştir. Çalışmada Yahoo Finance veri tabanı aracılığıyla elde edilen BIST 100 endeksine ait 01.01.2015 - 31.12.2025 tarihleri arasındaki günlük veriler kullanılmıştır. Veri seti; “Tarih”, “Açılış Fiyatı”, “En Yüksek Fiyat”, “En Düşük Fiyat”, “Kapanış

Fiyatı”, “Düzeltilmiş Kapanış Fiyatı” ve “Hacim” olmak üzere 7 değişkenden oluşmakta olup, hedef değişken olarak “Kapanış Fiyatı (Close)” seçilmiştir.

Endeks verilerinin elde edilmesi ve analizlerin gerçekleştirilmesi için Python programlama dili ve Google Colab geliştirme ortamı kullanılmıştır. BIST 100 endeksine ait günlük kapanış fiyatının 01.01.2015 - 31.12.2025 dönemi için fiyat hareketleri Şekil 2’de görülmektedir.



Şekil 2: BIST 100 endeks değerinin günlük kapanış fiyatı

Yahoo Finance üzerinden alınan veri setinin ağ modellerine uygun hale getirilmesi ve farklı ölçeklerdeki verilerin eğitim sürecini olumsuz etkilemesinin (gradyan kaybolması vb.) önüne geçilmesi amacıyla veri ön işleme adımı gerçekleştirilmiştir. Bu aşamada normalizasyon (ölçeklendirme) işlemi uygulanarak dağılım yapısı farklı olan verilerin belirli bir aralıkta kalması amaçlanmıştır. Bu amaçla LSTM modellerinde verimli bir yakınsama sağlamak için “sklearn” kütüphanesi kullanılarak Min-Max normalizasyonu uygulanmış ve tüm değerler [0-1] aralığına ölçeklendirilmiştir. TCN ve LSTM modellerinin eğitimi ve test aşaması için veri seti, zaman serisinin sıralı yapısı korunarak %80 eğitim verisi ve %20 test verisi olmak üzere iki alt gruba ayrılmıştır. Ayrıca eğitim esnasında model doğrulama işlemi için eğitim kümesinin %10’u doğrulama kümesi olacak şekilde ayrılmıştır.

4. Bulgular

BIST 100 endeksi kapanış fiyatının tahmin edilmesinde, modellerin veri setindeki karmaşık ve uzun vadeli bağımlılıkları öğrenebilmesi için LSTM ve TCN mimarileri tasarlanmıştır. Bu aşamada katman sayısı, nöron sayısı, çekirdek

boyutu, genişletme oranı vb. gibi ağ yapılarına ait bileşenler için Hyperband algoritması kullanılarak hiperparametre optimizasyonu gerçekleştirilmiştir. Her iki model için ayrı ayrı gerçekleştirilen hiperparametre optimizasyonu sonucunda en düşük hata değerini veren parametre kombinasyonu seçilmiştir. Hiperparametre optimizasyonu sonrasında TCN ve LSTM yapıları için en uygun girdi parametreleri Tablo 1'deki gibi belirlenmiştir.

Tablo 1: LSTM ve TCN Modelleri için Optimum Hiperparametreler

Parametre	LSTM	TCN
<i>Katman / Blok Sayısı</i>	1 katman	1 blok
<i>Nöron / Filtre Sayısı</i>	128 nöron	128 filtre
<i>Çekirdek Boyutu</i>	–	3
<i>Genişletme Oranları</i>	–	[1, 2, 4, 8]
<i>Alıcı Alan</i>	–	61 gün
<i>Dropout Oranı</i>	0.2	0.2
<i>Batch Boyutu</i>	64	32
<i>Pencere Boyutu</i>	60 gün	60 gün
<i>Optimizasyon Algoritması</i>	Adam	Adam
<i>Kayıp Fonksiyonu</i>	MSE	MSE

Tablo 1'e göre LSTM mimarisinde tek giriş katmanı, 128 nörondan oluşan 1 gizli katman ve 1 yoğun (Dense) çıkış katmanı tasarlanmıştır. TCN mimarisinde ise filtre sayısı 128 olarak belirlenirken çekirdek boyutu 3 olarak tasarlanmıştır. Genişletme oranı ise [1, 2, 4, 8] olarak uygulanmıştır. Her iki modelde de aşırı öğrenme problemini önlemek için Dropout oranı 0,2 olarak belirlenmiştir. Modellerde optimizasyon algoritması olarak "Adam" ve kayıp fonksiyonu olarak ise "Ortalama Kare Hata (MSE)" kullanılmıştır. Bu parametrelerle LSTM modeli 64 batch ve TCN modeli 32 batch büyüklüğünde 100 epoch boyunca eğitilmiştir. Her iki ağ yapısı için belirlenen parametrelere göre modeller eğitilip test verilerine göre tahmin edilmiştir ve tahmin değerleri için ters dönüşüm (transform) işlemi uygulanarak gerçek değerlere dönüştürülmüştür.

Zaman serisi tahmin modelinin performansını ölçmek amacıyla hata değerlendirme ölçütlerinin karşılaştırılması kritik bir rol oynamaktadır. Hesaplanan hata değeri arttıkça, model gerçek değerlerden uzaklaşmakta ve tahmin doğruluğu azalmaktadır. Bu durum, modelin daha düşük bir performans sergilediğini göstermektedir (Yu vd., 2025). Böylece tahmin değerleri ile gerçek değerler arasındaki fark dikkate alınarak en başarılı sonucu ortaya koyan model belirlenebilmektedir. Çalışmada her bir model için tahmin

edilen değerler ile gerçek değerler arasındaki farkı esas alan Kök Ortalama Kare Hata (RMSE), Ortalama Mutlak Hata (MAE) ve Ortalama Mutlak Yüzde Hata (MAPE) ölçütleri kullanılmıştır. Bu ölçütlere ait denklemler Eşitlik 7, Eşitlik 8 ve Eşitlik 9'da yer almaktadır:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} * 100 \quad (9)$$

Burada n ; örneklem sayısını, y_i ve \hat{y}_i değerleri sırasıyla t anındaki gerçek endeks değeri ve tahmini endeks değerini göstermektedir. RMSE ve MAE ölçütleri $[0, +\infty]$ aralığında değerler almaktadır. Bu hata metriklerinin değerleri 0'a yaklaştıkça tahmin edilen değerler ile gerçek değerler arasındaki farkın azaldığı ve modelin başarısının arttığı söylenebilir. Bu fark 0'dan uzaklaştıkça tahmin sonuçlarının daha başarısız olduğu ifade edilebilir (Shi, Ibrahim & Hashim, 2025; Yu vd., 2025). LSTM ve TCN modellerine göre BIST 100 endeks değerine ilişkin hata ölçütlerine ait değerler Tablo 2'de yer almaktadır.

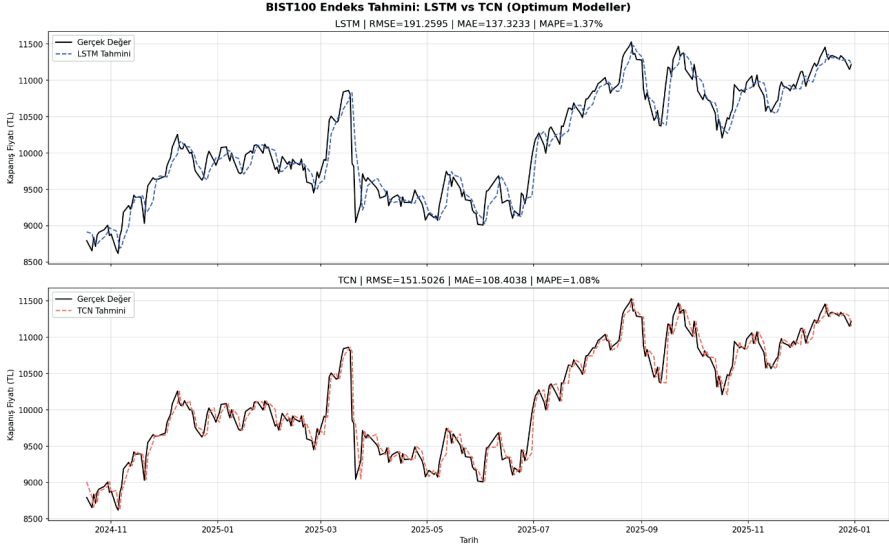
Tablo 2: LSTM ve TCN Modellerinin BIST 100 Tahmin Performansları Karşılaştırması

Model	Hata Ölçütleri		
	RMSE	MAE	MAPE (%)
TCN	151,5026	108,4038	1,08
LSTM	191,2595	137,3233	1,37

Tablo 2 incelendiğinde her iki derin öğrenme modelinin de BIST 100 endeksi gibi yüksek volatiliteye sahip finansal bir zaman serisinde oldukça düşük hata payları ile yüksek bir tahmin doğruluğuna ulaştığı görülmektedir. Ancak her üç hata metriği bakımından TCN modelinin LSTM modeline belirgin bir üstünlüğü olduğu görülmektedir. RMSE değeri bakımından TCN modeli (151,5026) LSTM modeline (191,2595) göre daha düşük hata üretmiştir. Benzer şekilde TCN'nin MAE değeri (108,4038), LSTM'ye (137,3233) göre %21,1 oranında daha düşük olarak belirlenmiştir. MAPE

değerlerine göre de LSTM ortalama %1,37 hata üretirken TCN ise ortalama %1,08 hata üretmektedir. Bu durum LSTM yapısına kıyasla TCN ağ yapısının BIST 100 endeksindeki ani değişimlere ve trend değişimlerine daha iyi uyum sağladığını göstermektedir.

LSTM ve TCN ağ yapılarına göre elde edilen tahmin değerleri ile gerçek değerlerin test dönemi boyunca karşılaştırmalı sonuçları ise Şekil 3'te yer almaktadır.



Şekil 3: BIST 100 Endeks Tahmini: LSTM ve TCN Modellerinin Karşılaştırmalı Sonuçları

Şekil 3 incelendiğinde tahmin sonuçlarının test verilerine oldukça yakın olduğu ve her iki modelin endeks değerini gerçek değerlere yakın bir şekilde tahmin ettiğini göstermektedir. Ancak LSTM modelinin tahmin çizgisi (mavi kesikli çizgi) takip edildiğinde trendi yakalamakta başarılı olmasına rağmen endeksin dip veya zirve noktalarındaki dönüşlerde gecikmeler yaşadığı görülmektedir. TCN modelinin tahmin çizgisi (turuncu kesikli çizgi) ise gerçek değerlere oldukça yakın hareket ederek ani hareketleri ve dönüm noktalarını başarılı bir biçimde izlemektedir. Bu durum, LSTM modeline kıyasla TCN'nin BIST 100 endeksi değerindeki kısa vadeli değişimleri tahmin etmekte daha güçlü olduğunu göstermektedir.

5. Sonuç ve Tartışma

Zaman serisi verilerinin analizinde ve sıralı bilgilerin işlenmesinde RNN modeli, geçmiş dönemden öğrendiği bilgileri hafızasında tutarak ardışık bağımlılıkları yakalayabilme yeteneği ile öne çıkmaktadır (Alp, 2025). Ancak RNN ağında zaman adımları arttıkça, her adımda bilgi kaybı problemi ile karşılaşmaktadır. Bu durum, ağıın başlangıcındaki önemli bilgilerin unutulmasına ve uzun vadeli bağımlılıkların öğrenilememesine neden olmaktadır.

Bu çalışmada, BIST 100 endeks değerinin uzun dönemli bağımlılık yapısı ve doğrusal olmayan yapısı dikkate alınarak iki farklı derin öğrenme yöntemine göre endeks değerinin tahmin edilmesi amaçlanmıştır. Bu doğrultuda, 2015-2025 yılları arasındaki BIST 100 endeks kapanış fiyatları için LSTM ve TCN yapılarına göre tahminler gerçekleştirilmiştir.

Çalışmada elde edilen bulgulara göre her iki modelin de BIST 100 endeksinin genel yükseliş ve düşüş trendlerini başarıyla yakaladığı görülmektedir. LSTM'ye kıyasla TCN'nin elde edilen tahmin değerlerinin gerçek değerlere daha yakın sonuçlar verdiği belirlenmiştir. Hata metrikleri karşılaştırıldığında da LSTM'nin TCN'ye göre tahmin değerlerinde daha az başarılı olduğu saptanmıştır. Özellikle piyasanın yüksek değişkenlik gösterdiği dönemlerde TCN modelinin hata payının daha düşük olduğu görülmektedir. LSTM modeli ise ani piyasa değişimlerinde hafif gecikmeli reaksiyon göstermektedir. Bu durumda, TCN'nin BIST 100 endeksinin doğrusal olmayan fiyat dinamiklerini yakalamada LSTM'ye kıyasla daha başarılı sonuçlar ortaya koyduğu söylenebilir. Ayrıca aynı anda işlem yapma yeteneği sayesinde TCN mimarisinin, finansal tahmin süreçlerinde LSTM modeline kıyasla daha güçlü ve yenilikçi bir alternatif olduğu vurgulanabilir.

TCN modelinin evrişimli ağ yapısı, geniş bir geçmiş dönem veri aralığını aynı anda analiz ederek ani kırılmalara karşı daha isabetli sonuçlar elde edilmesini sağlamaktadır. Ayrıca artık bağlantılar sayesinde ağ derinliği artmasına rağmen gradyan kaybolması problemlerini önleyerek daha tutarlı tahminler ortaya koymaktadır. Bu nedenle TCN mimarisi, uzun dönemli verilerin yer aldığı zaman serilerinde güçlü bir yaklaşım olarak düşünülebilir. Bundan sonraki çalışmalarda farklı hibrit modellerin finansal piyasalardaki rolü ve tahmin başarısı karşılaştırmalı olarak incelenebilir.

Kaynakça

- Akbulut, S., & Adem, K. (2023). Derin öğrenme ve makine öğrenmesi yöntemleri kullanılarak gelişmekte olan ülkelerin finansal enstrümanlarının etkileşimi ile Bist 100 tahmini. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(1), 52-63.
- Al-Khasawneh, M. A., Raza, A., Khan, S. U. R., & Khan, Z. (2025). Stock market trend prediction using deep learning approach. *Computational Economics*, 66(1), 453-484.
- Almasarweh, M., & Wadi, S. A. (2018). ARIMA model in predicting banking stock market data. *Modern Applied Science*, 12(11).
- Alp, E. C. Yinelemeli Sinir Ağları (RNN) Uzerine Kavramsal Bir Inceleme.
- Alhawatmeh, O. (2022). Share price forecast: using ARIMA model special study on Amman Stock Exchange (ASE). *Italian Journal of Pure and Applied Mathematics*, 47, 173-181.
- Arslankaya, S., & Toprak, Ş. (2021). Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini. *International Journal of Engineering Research and Development*, 13(1), 178-192.
- Bai, S., Kolter, J. Z., & Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv preprint arXiv:1803.01271*.
- Çelik, Y. (2024). Bellek tabanlı LSTM ve GRU makine öğrenmesi algoritmaları kullanarak BIST100 endeks tahmini. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 36(2), 553-561.
- Çoban, Ç., & Hayat, E. (2023). Hisse Senedi piyasası analizinde farklı derin sinir ağı modellerinin karşılaştırılması. *Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(2), 120-139.
- Demirci, E., & Karaatlı, M. (2023). Kripto para fiyatlarının lstm ve gru modelleri ile tahmini. *Journal of Mehmet Akif Ersoy University Economics and Administrative Sciences Faculty*, 10(1), 134-157.
- Dehghani, A., Moazam, H. M. Z. H., Mortazavizadeh, F., Ranjbar, V., Mirzaei, M., Mortezaei, S., ... & Dehghani, A. (2023). Comparative evaluation of LSTM, CNN, and ConvLSTM for hourly short-term streamflow forecasting using deep learning approaches. *Ecological Informatics*, 75, 102119.
- Eapen, J., Bein, D., & Verma, A. (2019, January). Novel deep learning model with CNN and bi-directional LSTM for improved stock market index prediction. In *2019 IEEE 9th annual computing and communication workshop and conference (CCWC)* (pp. 0264-0270). IEEE.
- Fan, Z., Liang, R., & Hu, Y. (2025). A FEDformer-Based Hybrid Framework for Anomaly Detection and Risk Forecasting in Financial Time Series. *arXiv preprint arXiv:2511.12951*.

- Ghosh, A., Bose, S., Maji, G., Debnath, N., & Sen, S. (2019, September). Stock price prediction using LSTM on Indian share market. In *Proceedings of 32nd international conference on* (Vol. 63, pp. 101-110).
- Haijian, W., & Qianqian, L. (2017). Empirical study on Shanghai composite index forecast based on ARIMA model. *Journal of World Economic Research*, 6(6), 71-74.
- He, Y., & Zhao, J. (2019, June). Temporal convolutional networks for anomaly detection in time series. In *Journal of Physics: Conference Series* (Vol. 1213, No. 4, p. 042050). IOP Publishing.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Ingle, V., & Deshmukh, S. (2021). Ensemble deep learning framework for stock market data prediction (EDLF-DP). *Global transitions proceedings*, 2(1), 47-66.
- Kara, A. (2019). Global solar irradiance time series prediction using long short-term memory network. *Gazi Üniversitesi Fen Bilimleri Dergisi, Part C: Tasarım ve Teknoloji*, 4(7), 882-892.
- Li, J. (2024). Short-Term Urban Rail Passenger Flow Prediction using TCN-LSTM Model. *Highlights in Science, Engineering and Technology*, 118, 25-33. <https://doi.org/10.54097/p83p5860>
- Li, L., Liu, Z., Fang, X., & Qi, W. (2024). Multi-step real-time prediction of hard-rock TBM penetration rate combining temporal convolutional network and squeeze-and-excitation block. *Scientific Reports*, 14(1), 14326.
- Li, M., Yang, K., Lin, W., Wei, Y., & Wang, S. (2024). An interval constraint-based trading strategy with social sentiment for the stock market. *Financial Innovation*, 10(1), 56.
- Mashadihasanli, T. (2022). Stock market price forecasting using the ARIMA model: an application to Istanbul, Türkiye. *İktisat Politikası Araştırmaları Dergisi*, 9(2), 439-454.
- Mukherjee, S., Sadhukhan, B., Sarkar, N., Roy, D., & De, S. (2023). Stock market prediction using deep learning algorithms. *CAAI Transactions on Intelligence Technology*, 8(1), 82-94.
- Nikou, M., Mansourfar, G., & Bagherzadeh, J. (2019). Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms. *Intelligent Systems in Accounting, Finance and Management*, 26(4), 164-174.
- Odabaşı, M. B., & Toklu, M. C. (2023). Yapay sinir ağları ve derin öğrenme algoritmalarının kripto para fiyat tahmininde karşılaştırmalı analizi. *Journal of Intelligent Systems: Theory and Applications*, 6(2), 96-107.

- Rawlin, R. S., & Pakalapati, S. S. N. R. (2022). Forecasting stock prices of select Indian private sector banks—a time series approach. *Sdmimd Journal of Management*, 13(1), 35.
- Rezaei, H., Faaljou, H., & Mansourfar, G. (2021). Stock price prediction using deep learning and frequency decomposition. *Expert Systems with Applications*, 169, 114332.
- Selvin, S., Vinayakumar, R., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2017, September). Stock price prediction using LSTM, RNN and CNN-sliding window model. In *2017 international conference on advances in computing, communications and informatics (icacci)* (pp. 1643-1647). IEEE.
- Shi, Z., Ibrahim, O., & Hashim, H. I. C. (2025). Stock Index Prediction Using Temporal Convolutional Network and Long Short-Term Memory Network Optimized by Genetic Algorithm. *Journal of Wireless Mobile Networks, Ubiquitous Computing, and Dependable Applications*, 16(1), 508-527.
- Sonkavde, G., Dharrao, D. S., Bongale, A. M., Deokate, S. T., Doreswamy, D., & Bhat, S. K. (2023). Forecasting stock market prices using machine learning and deep learning models: A systematic review, performance analysis and discussion of implications. *International Journal of Financial Studies*, 11(3), 94.
- Sudipa, I. G. I., Riana, R., Putra, I. N. T. A., Yanti, C. P., & Aristana, M. D. W. (2023). Trend Forecasting of the Top 3 Indonesian Bank Stocks Using the ARIMA Method. *Sinkron: jurnal dan penelitian teknik informatika*, 7(3), 1883-1893.
- Şişmanoğlu, G., Koçer, F., Önde, M. A., & Sahingoz, O. K. (2020). Derin öğrenme yöntemleri ile borsada fiyat tahmini. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 434-445.
- Wang, Y., Liu, Z., Hu, D., & Zhang, M. (2019, October). Multivariate time series prediction based on optimized temporal convolutional networks with stacked auto-encoders. In *Asian Conference on Machine Learning* (pp. 157-172). PMLR.
- Variürer, İ., Özeydin, Ö., & Çemrek, F. (2025). BIST100 Endeksi Fiyatının LSTM, CNN-LSTM ve BILSTM Modelleri ile Tahmin Edilmesi. *Ekonomi ve Yönetim Araştırmaları Dergisi*, 14(2), 1-24.
- Yang, B., Gong, Z. J., & Yang, W. (2017, July). Stock market index prediction using deep neural network ensemble. In *2017 36th chinese control conference (ccc)* (pp. 3882-3887). IEEE.
- Yeung, K. (2024). ARIMA Model Application in Predicting NVIDIA's Stock Price. *Advances in Economics Management and Political Sciences*, 128(1):220-230.
- Yi, Z. (2024). Analysis of Stock Market Prices Based on ARIMA Model: Evidence from NASDAQ 100 Index. *Advances in Economics Management and Political Sciences*, 88(1):89-98.

- Yu, Q., Yang, G., Wang, X., Shi, Y., Feng, Y., & Liu, A. (2025). A review of time series forecasting and spatio-temporal series forecasting in deep learning: Q. Yu et al. *The Journal of Supercomputing*, 81(10), 1160.
- Zeroual, A., Harrou, F., Dairi, A., & Sun, Y. (2020). Deep learning methods for forecasting COVID-19 time-Series data: A Comparative study. *Chaos, solitons & fractals*, 140, 110121.
- Zhang, Z. (2023). An Empirical Study of Shanghai Composite Index Forecasts and Trend Trading Strategies Based on ARIMA Model. *Advances in Economics Management and Political Sciences*, 65(1):302-308.
- Zhang, C., Sjarif, N. N. A., & Ibrahim, R. (2024). Deep learning models for price forecasting of financial time series: A review of recent advancements: 2020–2022. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 14(1), e1519.
- Zhang, Y., Zhang, T., & Hu, J. (2025). Forecasting stock market volatility using CNN-BiLSTM-Attention model with mixed-frequency data. *Mathematics*, 13(11), 1889.
- Zíková, A., & Veselá, J. (2023). Forecasting Analysis of Stock Prices on European Markets Using the ARIMA-GARCH Model. *Statistika: Statistics & Economy Journal*, 103(3).