

## Finansal Stres Endeksinin Dalgacık Dönüşümlü Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi

Predicting Financial Stress Index Using Wavelet Transform Artificial Neural Networks

### Öz

Finansal risk ve belirsizlikler nedeniyle karşılaşılan problemler dikkate alındığında, finansal stres endeksinin belirlenmesi büyük önem taşımaktadır. Çalışma ile makine öğrenmesi yöntemleri kullanılarak finansal stres endeksi seviyesinin tahmin edilmesi amaçlanmaktadır. Bu amaçla finansal stres endeksinin haftalık zaman serileri, bağımsız ve hibrit modeller kullanılarak incelenmiştir. Yapay sinir ağları, bağımsız makine öğrenme modelleri olarak kullanılırken, hibrit modeller oluşturmak için bir ön işleme tekniği olarak dalgacık dönüşümü kullanılmıştır. Ayrıca, finansal stres endeksi tahminlerinde, model doğruluklarını artırmak için otokorelasyon fonksiyonlarını kullanarak gecikme uzunlukları elde edilmiştir. Çalışmanın bulguları, çeşitli performans göstergeleri açısından değerlendirilmiştir. Finansal stres endeksinin tahmin edilmesinde dalgacık dönüşümlü yapay sinir ağları modelinin, yalın yapay sinir ağları modelinden daha iyi performans sergilediği tespit edilmiştir. Çalışma sonuçlarının finansal stres endeksini takip eden araştırmacı ve uygulayıcılar için fayda sağlayacağı düşünülmektedir.

### Abstract

Considering the problems encountered due to financial risks and uncertainties, it is of great importance to determine the financial stress index. The aim of the study is to predict the level of financial stress index by using machine learning methods. For this purpose, the weekly time series of the financial stress index were examined using independent and hybrid models. While artificial neural networks are used as stand-alone machine learning models, wavelet transform is used as a preprocessing technique to create hybrid Models. In addition, lag lengths were obtained by using autocorrelation functions to increase model accuracy in financial stress index predictions. The findings of the study were evaluated in terms of various performance indicators. It has been determined that the wavelet transform artificial neural network model performs better than the pure artificial neural network model in predicting the financial stress index. It is thought that the results of the study will be beneficial for researchers and practitioners following the financial stress index.

### Giriş

Stres, hassas bir yapının ve bazı dışsal şokların ürünü olarak bilinmektedir. Finansal kırılma ise, finansal koşullardaki veya finansal sistemin yapısındaki zayıflıklar olarak tanımlanmaktadır. Finansal koşulların zayıf olduğu durumlarda herhangi bir şokun stresle sonuçlanma ihtimali artmaktadır. Şoklar finansal sistemin yapısında oluşan zayıflık yoluyla da yayılabilmektedir. Şokun boyutu ve finansal sistem kırılma durumlarının etkileşimi stres düzeyini belirlemektedir (Lling ve Liu, 2006: 244-245). Finansal sistem, şirketlerin ve hane halklarının ekonomik büyümeye katkıda bulunmasını kolaylaştırabilecek sermayeye aracılık etme işlevi görmektedir. Bu fonlama sermaye piyasası ile mümkün olmaktadır. Dolayısıyla piyasanın verimli çalışmasını engelleyen şoklara maruz kalmaması önem arz etmektedir. Sermaye piyasasının, finansal sistemin merkezinde yer alması, finansal stres endeksi için doğal bir başlangıç noktası olarak kabul edilmektedir (Sandahl vd., 2011: 52).

Finansal stres dönemi, finansal sistemin baskı altında olduğu ve aracılık yeteneğinin bozulduğu bir dönem olarak tanımlanmaktadır. Finansal piyasa koşullarını etkileyen olaylar çeşitlilik

### Salim Sercan Sarı

Dr. Öğr. Üyesi, Erzincan Binali Yıldırım Üniversitesi, İşletme ABD, Erzincan, Türkiye, salim.sari@erzincan.edu.tr, Orcid No: <https://orcid.org/0000-0003-2607-5249>

### Article Type / Makale Türü

Research Article / Araştırma Makalesi

### Anahtar Kelimeler

Finansal Stres Endeksi, Makine Öğrenme, Yapay Sinir Ağları, Dalgacık Dönüşümlü Yapay Sinir Ağları.

### Keywords

Financial Stress Index, Machine Learning, Artificial Neural Networks, Artificial Neural Networks with Wavelet Transforms.

JEL: C22, G17, G20

Submitted: 09 / 08 / 2022

Accepted: 26 / 09 / 2022

gösterebilmekte ve yatırımcıların riski yeniden değerlendirmeleri, tercihlerde değişiklikler veya beklenmeyen finansal veya kurumsal kayıplar gibi sonuçları olabilmektedir. Genel olarak, bu tür olaylar finansal piyasalardaki fon arzını veya talebini ve dolayısıyla varlık fiyatlarını şekillendirdiği için finansal sistemin birden çok bölümünü etkileyebilmektedir (Balakrishnan vd., 2011:44). Finansal stres, finansal piyasaların normal işleyişinde bir kesinti olarak düşünülebilmektedir. Finansal strese sebep olan ekonomik olaylar farklılık gösterdiği için finansal stres çeşitli şekillerde tanımlanabilmektedir. Söz konusu tanımlamalar; varlıkların temel değerinde artan belirsizlik, diğer yatırımcıların davranışlarında artan belirsizlik, bilgi asimetrisi, riskli varlıkları elde tutma isteğindeki azalma ve likit olmayan varlıkları elde tutma isteğindeki azalma şeklinde ifade edilebilmektedir (Hakkio ve Keeton, 2009: 6). Finansal stres, uç değerlerin kriz olarak adlandırıldığı, değerler çeşitliliğine sahip sürekli bir değişkendir. Finansal stres, beklenen finansal kayıpla, riskle veya belirsizlikle artmaktadır (Lling ve Liu, 2006: 244). Diğer taraftan düşük dış kırılganlıklar ve güçlü bir politika, finansal stres aktarımını azaltmaktadır. Ancak bir ülkenin finans sektörünü büyük bir şoka karşı koruyamamaktadır (Balakrishnan vd., 2009: 5).

Finansal çalkantı dönemleri, bankacılık, menkul kıymetler veya döviz piyasalarından kaynaklanan stresi işaret edebilen, yüksek frekanslı fiyat değişkenlerine dayanan ve yeni bir endeks olan finansal stres endeksi kullanılarak tanımlanmaktadır. Finansal stres endeksi, yalnızca literatürde tanımlanan finansal stres dönemlerini doğru bir şekilde tahmin etmekle kalmamakta, aynı zamanda gerilemelerle ilişkili olmayan stres dönemlerini de ortaya koymaktadır (Cardarelli vd., 2011: 79). Finansal stres endeksi, referans değişkeni geliştirerek erken uyarı göstergelerini kullanan modellerde bulunan zayıflığı gidermektedir. Finansal stres endeksi sürekli ve yüksek frekanslıdır. Hisse senedi piyasalarını, tahvil piyasalarını, döviz piyasalarını ve bankacılık sektörünü kapsamaktadır. Bu nedenle, sistemik olarak çok sayıda finansal piyasa ve kuruma sahip olan gelişmiş ülkelerde finansal istikrarı analiz etmek için uygulanabilmektedir (Lling ve Liu, 2006: 244). Son yıllarda Covid-19 pandemisi ve benzeri beklenmedik olaylar nedeniyle finansal stres endeksinde önemli değişiklikler gözlenmektedir. Bu değişikliklerin anlaşılması, finansal piyasaların etkin kullanımı ve olası olumsuz etkilerin önlenmesi açısından önemlidir.

Zaman serisi tahmin yöntemlerinden, zaman içinde finansal göstergelerdeki değişiklikleri tespit etmek için yararlanılmaktadır. Zaman serilerini modellemek için kullanılan otoregresif yöntemler, doğrusal olmayan işlemlerin davranışını yansıtmak için her zaman yeterli olmayabilir. Bu nedenle doğrusal tahmin yöntemlerine alternatif olarak geliştirilen makine öğrenmesi yöntemleri finans alanında sıklıkla kullanılmaya başlanmıştır. Finansal tahminlerde derin öğrenme olarak bilinen makine öğrenme yöntemlerinin öneminin fark edilmesi aşağıda örnekleri verildiği gibi oldukça çok sayıda çalışmada kullanılmasına neden olmaktadır.

Aksoy, 2021 çalışmasında BİST 30 Endeksinde ve Kurumsal Yönetim Endeksinde bulunan beş imalat sanayi şirketinin pay senedi fiyat yönünü YSA ile tahmin etmiştir. Arslankaya ve Toprak, 2021; Ayala vd., 2021; Karacan ve Kırdar, 2021; Ebadati ve Mortazavi, 2018 çalışmalarında makine öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini yapmışlardır. Aker, 2022; Kaynar ve Yiğit, 2021; Pabuçcu, 2019; Ghazanfar vd., 2017; Patel vd., 2015; Aygören vd., 2012 çalışmalarında makine öğrenme yöntemleri ile Borsa Endeksini tahmin etmişlerdir. Kartal, 2020 BIST100, S&P 500, DAX ve NIKKEI 225 endekslerinin getiri yönlerinin sınıflandırılmasında bir makine öğrenme tekniği olan DVM ile tahmin performanslarını ortaya koymuştur. Parray vd., 2020 çalışmalarında makine öğrenme yöntemlerini kullanarak hisse senetlerinin bir sonraki gün trendlerini tahmin etmişlerdir. Akay vd., 2019; Dingli ve Fournier, 2017 çalışmalarında makine öğrenme yöntemlerini kullanarak fiyat endeksi tahmininde bulunmuşlardır. Literatürde yapılan çalışmaların etkin tahminlerde bulunması nedeniyle bu çalışmada da finansal stres endeksi makine öğrenmesi yöntemleri ile tahmin edilmeye çalışılmıştır.

Geçmiş literatürde finansal stres endeksi tahminleri için elde edilen istatistikî sonuçlar ayrıntılı olarak incelenmiştir. Bu çalışmada finansal stres endeksinin gelecekte nasıl hareket edeceğinin tahmin edilmesi amaçlanmıştır. Söz konusu amaç doğrultusunda iki farklı yöntem kullanılmıştır. İlk olarak yapay sinir ağları yöntemi (YSA) ile en iyi performans gösteren model seçilmiştir. Ardından finansal stres endeksi zaman serisi değerlerinde yaşanabilecek dalgalanmaları

anlamlandırabilmek ve elimine etmek için dalgacık dönüşümlü-YSA (DD-YSA) yöntemi uygulanmıştır. Burada, mevcut araştırmanın yeniliği, finansal stres endeksi tahmininde YSA'yı DD-YSA ile entegre etmek için ilk girişim olması gerçeğinden kaynaklanmaktadır. Bu çalışma aynı zamanda finansal stres endeksi tahmininde dalgacık dönüşümü parametrelerinin optimizasyonu açısından da ilk olma özelliği taşımaktadır.

### 1. Literatür Taraması

Konuyla ilgili literatür incelendiğinde finansal stres endeksi tahmini üzerine yapılmış çalışmalar aşağıda özetlenmiştir.

Hoque ve Low (2022) çalışmalarında COVID-19 salgını öncesi ve süresince Bitcoin ve altının kategorik finansal strese verdiği tepkileri incelemişlerdir. Sıradan En Küçük Kareler Yöntemi ve Nicel regresyon tahminlerine göre, altın ve Bitcoin COVID-19 öncesi örneklerde benzer reaksiyonlar göstermiştir. Altın ve Bitcoin, öz sermaye değerlemesi ve finansal stresin güvenli varlık kategorilerine olumlu yanıt vermiştir. Ayrıca altın, finansal stresin kredi kategorisine de olumlu tepki vermiştir. Pandemi sırasında altın ve Bitcoin'in kategorik finansal strese tepkileri değişmiştir.

Xiong vd. (2022) çalışmalarında karışık frekanslı veri örnekleme modelini kullanarak, ekonomik politika belirsizliğinin finansal stresi tahmin edip edemeyeceğini incelemişlerdir. Sonuç olarak, ekonomik politika belirsizliğinin gelecekteki finansal stres üzerinde önemli bir pozitif etkiye sahip olduğunu ve ekonomik politika belirsizliğinin finansal stresin bir belirleyicisi olduğunu göstermişlerdir. Ayrıca örnek dışı tahmin sonuçları, karışık frekanslı veri örnekleme modelinin geleneksel zaman serisi OLS modelinden daha iyi performans gösterdiğini ortaya koymuştur.

Polat (2021) çalışmasında petrol fiyat şokları ile AB bölgesi finansal stres endeksi arasındaki dinamik aktarım mekanizmasını incelemiştir. Sonuçta, pozitif petrol fiyat şoklarının AB bölgesi finansal koşullarını kötüleştirdiği belirtilmiştir.

Alsu (2020) çalışmasında 1994-2018 dönemi için finansal stres endeksi ile doğrudan yabancı yatırımlar, portföy yatırımları ve dış borç stoku arasındaki ilişkiyi araştırmıştır. Sonuçta finansal stres endeksinde oluşan bir artışın ülkenin portföy yatırımlarını azalttığı, diğer taraftan dış borç stoğunu artırdığı belirtmiştir. Finansal stres endeksi ile doğrudan yabancı yatırımlar arasında anlamlı bir ilişki bulunamamıştır.

Monin (2019) çalışmasında Finansal Araştırma Ofisi tarafından geliştirilen bir finansal stres endeksi sunmuştur. Endekste, küresel finans piyasalarından günlük verileri kullanan yeni ve esnek bir metodoloji kullanılmıştır. 2000-2018 dönemi için yapılan analizde finansal stres endeksinin sistemik finansal stresi belirlemede iyi performans gösterdiği bulunmuştur.

Bülbül ve Akgül (2018) çalışmalarında 1990-2017 döneminde Türkiye'de finansal istikrarı izleyebilmek için bir finansal stres endeksi meydana getirerek finansal aktörlere yarar sağlamayı amaçlamışlardır. Endekste bulunan değişkenler, finansal piyasalardaki yüksek stres durumlarını belirleyen değişkenler içinden tespit edilmiştir. Finansal stres endeksi için tanımlanan modeller yardımıyla düşük, normal ve yüksek stres dönemleri gösterilmiştir. Kriz dönemlerinde yüksek stresin olduğu bulgusu elde edilmiştir.

Luo vd. (2018) çalışmalarında çekirge optimizasyon algoritmasını finansal stres tahmini için kullanmışlardır. Uygulamada denge sağlamak için üç stratejiyi birleştiren iyileştirilmiş bir çekirge optimizasyon algoritması kurulmuştur. Söz konusu algoritmaya dayanarak, finansal stres tahmini için makine öğrenmesi modeli geliştirilmiştir. Sonuçta çekirge optimizasyon algoritmasının tahmin performansını önemli ölçüde artırdığı gösterilmiştir.

Duprey ve Klaus (2017) çalışmalarında Markov geçiş çerçevesinde sürekli bir finansal stres ölçüsü kullanarak finansal döngünün aşamalarını tahmin etmiştir. Borç servis oranı ve emlak piyasası değişkenlerinin, yüksek bir finansal stres rejimine geçişi gösterdiği, ekonomik duyarlılık göstergelerinin ise sakin bir duruma geçişi gösterdiği belirlenmiştir. Örnek içi analiz, bu göstergelerin ilgili rejim değişikliğinden sonra birkaç çeyreğe kadar erken uyarı sinyali sağlayabileceğini göstermiştir. Örnek dışı bulgular ise bu performansın çoğunun, küresel finansal kriz sırasında toplanan verilerden kaynaklandığını göstermiştir. Markov modelinin tahmin performansının diğer modellerin çoğunluğundan daha etkili olduğu ortaya konulmuştur.

Kaya ve Kılınc (2017) çalışmalarında aylık bazda belirli dönemi kapsayan finansal sıkıntı endeksi oluşturmuşlardır. Sonuçta, finansal sıkıntı endeksinin finansal krizleri başarılı bir şekilde yansıttığını göstermişlerdir. Ayrıca finansal sıkıntı ve ekonomik aktiviteler arasındaki ilişkiyi incelemiş ve finansal sıkıntı endeksinin ekonomik aktiviteleri istatistiksel olarak anlamlı şekilde etkilediğini belirlemişlerdir.

Çamlıca ve Güneş (2016) çalışmalarında 2002-2015 yılları arasında Türkiye’de eşit varyans ağırlıklandırma, temel bileşenler analizi ve portföy teorisi ağırlıklandırma yöntemi ile finansal stresi hesaplamışlardır. Kullanılan üç yöntemin finansal stresi belirleyebilmek için başarılı performans sergilediği görülmüştür. Ayrıca portföy teorisi ağırlıklandırma yöntemi kullanılarak hesaplanan stres endeksinin, farklı stres dönemlerinde finansal stres-ekonomik aktivite bağlantısı kapsamında finansal stresin ölçülmesi ve takip edilmesinde daha başarılı performans elde edilmiştir.

Vdovychenko ve Oros (2015) çalışmaları finansal stres endeksinin tahmin etmek için ileri düzey bilimsel araştırmalara genel bir bakış niteliğindedir. Finansal piyasalarda oluşan krizi takip etmek için bir araç olarak göstergenin teorisini ve pratik uygulamalarını açıklamışlardır. Önceki bulgulara ve ulusal finansın özel taleplerine dayanarak, Ukrayna finansal stres endeksinin kendi tahmin konseptini sunmuşlardır. Maliye politikasını analiz etmek için bu endeksin analitik yeteneklerini göstermişlerdir. Finansal stres aralığının uç noktalarında maliye politikası davranışının aynı olduğu ve ortalama seviyeye ulaştığında ana parametrelerde çapsal değişiklikler yapıldığı bulunmuştur.

Ekinci (2013) çalışmasında Türkiye için günlük bazda bir finansal stres endeksi oluşturmuştur. Söz konusu finansal stres endeksten yola çıkılarak finansal kurumlar ile politika uygulayıcılara alt piyasalar ve toplam sektör üzerindeki finansal stresin algılanması, para politikasının yönetilmesi için günlük sıklığa sahip bir endeks sunulması amaçlanmıştır. Finansal Stres Endeksi aracılığıyla, Türkiye ekonomisi altı döneme ayrılarak ilgili dönemlerin analizleri ortaya koyulmuştur.

Slingenberg ve De Haan (2011) çalışmalarında 13 OECD ülkesi için finansal stres endeksi kullanarak finansal stresin tahmin edilmesine yardımcı olabilecek değişkenleri incelemişlerdir. Finansal stres endeksinin ortaya çıkarmak için çok ülkeli bir finansal stres endeksi oluşturulmuş ve üç kriter kullanılmıştır. Sonuçta finansal stresin tahmin edilmesinin zor olduğu gösterilmiştir.


## 2. Materyal ve Metodoloji

### 2.1. Veri Seti

Bu çalışma Federal Reserve Bank of St. Louis tarafından yayınlanan St Louis Financial Stress Index (STLFISI) verileri kullanılarak yapılmıştır. STLFISI, piyasalardaki finansal stresin derecesini ölçmektedir. Tümünü günlük veri serilerinin haftalık ortalamaları olan faiz oranı, getiri farkı ve diğer göstergelerin 18 haftalık veri setinden oluşturulmuştur. Bu değişkenlerin her biri finansal stresin bazı yönlerini dikkate almaktadır. Buna göre, ekonomideki finansal stres düzeyi değiştiğinde veri setlerinin birlikte hareket etme ihtimali bulunmaktadır. 1993 sonlarında başlayan STLFISI endeksinin ortalama değeri sıfır olarak tasarlanmıştır. Bu nedenle sıfır, normal finansal piyasa koşullarını temsil etmektedir. Sıfırın altındaki değerler, ortalamanın altında finansal piyasa stresini gösterirken, sıfırın üzerindeki değerler, ortalamanın üzerinde finansal piyasa stresini göstermektedir (FRED, 2022).

Federal Reserve Bank of St. Louis Dünya genelinde stres endeksi de dahil olmak üzere finansal parametreleri hesaplamaktadır. Bu çalışma kapsamında finansal stres endeksi zaman serisi incelenmiştir. 30 yıl boyunca (1993 Aralık-2022 Temmuz yılları arasında) haftalık periyotlarda kaydedilen finansal stres endeksi değerleri kullanılmıştır. Araştırma yöntemi olarak YSA ve DD-YSA kullanılmıştır. Yöntemleri uygulamak için R paket programından yararlanılmıştır.

Şekil 1’de gösterildiği üzere orijinal veri seti eğitim (%70) ve test (%30) olmak üzere iki bölüme ayrılmıştır. Haftalık finansal stres endeksi verilerinin zaman serisini ve tüm veri setinin yaklaşık %70’i modelleri eğitmek için ayrılmıştır. Verilerin geri kalan kısmı test için ayrılmıştır.



Şekil 1. Gerçekleşen Haftalık Finansal Stres Endeksi Değerlerinin Zaman Serileri

Zaman serisinin ortalama değeri 0,000000672, maksimum ve minimum sırasıyla 8,632 ve -1,627'dir. Ayrıca zaman serisinin standart sapması 0,999 ve çarpıklık 3,72 olarak hesaplanmıştır. Çarpıklık değeri verinin normal dağılım göstermediğini açıklamaktadır.

## 2.2. Araştırmanın Amacı

Finansal stres endeksinin finansal piyasalardaki istikrar ve reel ekonomi üzerinde yaşanan değişimlerde etkisi olduğu kabul edilmektedir. Finansal kararlar üzerine verilecek kararlarda etkiye sahip olan finansal stresin ölçülmesi veya tahmin edilmesi finansal durum açısından kritik önem taşımaktadır. Bu nedenle, bu çalışmanın temel amacı, finansal piyasalarda gözlenen finansal stres endeksi seviyelerini tahmin etmektir. Bu amacı gerçekleştirmek için dört ana adım izlenmiştir:

- 1) Tahminler için kullanılan gecikme sürelerinin belirlenmesi
- 2) Dalgacık dönüşümü aracılığıyla orijinal zaman serilerinin spektral bantlarına ayrıştırılması
- 3) YSA ve DD-YSA aracılığıyla tahminlerin gerçekleştirilmesi
- 4) Modellerin performanslarının istatistiksel olarak ölçülmesi

## 2.3. Araştırmanın Modelleri

### 2.3.1. Yapay Sinir Ağları (YSA)

Yapay sinir ağları, insan beyninin yeteneklerini ve çalışma ilkelerini taklit etmek için gelişmiş bilgisayar sistemleri ve beynin, biyolojik hücrelerin veya nöronların bileşiminin matematiksel modellenmesine odaklanan ön çalışmalar olarak ortaya çıkmıştır. YSA'lar karmaşık yapı problemlerinin çözümü için herhangi bir varsayım gerektirmeden değişkenler arasındaki ilişkiyi belirleyen çok yönlü bir yaklaşım olarak kabul edilmektedir. Ancak YSA'nın insan beyninden çok daha basit bir yapıya sahip olduğu düşünülmektedir. YSA'lar daha az bileşenden oluşmakta ve daha az karmaşık işlemler gerçekleştirilmektedirler. Sistemin ana işlem elemanı, çevreden veya diğer tüm nöronlardan girdi sinyalleri olarak çıktı üreten nörondur (Başakın vd., 2022: 786).

Çok katmanlı YSA, girdi katmanı, gizli katman ve çıktı katmanı olmak üzere 3 katmandan meydana gelmektedir. Girdi katmanı, sistemden giriş verilerini almaktan sorumlu nöronları kapsamaktadır. Bu katmandaki nöron sayısı giriş sayısından az olmamalıdır (Panchal vd., 2011: 332). Gizli katmanlar, alınan verilerin işlenmesini ve çıktı katmanına iletilmesini sağlamaktadır. Gizli katmanda kaç nöron olması ve kaç katmanın gruplanması gerektiğini belirleyen bir kural bulunmamaktadır. Probleme bağlı olarak gizli katman sayısı ve düğüm sayısının belirlenmesinde deneme-yanılma yöntemi kullanılmaktadır (Yiğiter vd., 2017).

Girdi verilerini YSA hücrelerinde işleyerek çıktı üreten fonksiyon aktivasyon fonksiyonları olarak tanımlanmaktadır. YSA'larda çok çeşitli aktivasyon fonksiyon tipleri kullanılmakla birlikte de en çok tercih edilen fonksiyonlar lineer, sigmoid, hiperbolik tanjant ve adım fonksiyonları olarak belirtilmektedir (Bueon ve Salmeron, 2009: 5223). Sigmoid transfer fonksiyonu, YSA çıkış genliğini 0 ile +1 aralığında sınırlarken, hiperbolik tanjant fonksiyonu, -1 ile +1 aralığında çıkış değerleri

vermektedir. Dolayısıyla YSA'larda kullanılacak aktivasyon fonksiyonu probleme bağlı olarak değişebilmektedir (Başakın vd., 2022: 786).

Model öğrenme işlemini gerçekleştirebilmek için tahmin değerleri ve gerçek değerler üzerinde bazı hesaplamalar yapar. Hedef değere olan uzaklık hata olarak adlandırılır ve hatanın minimize edilmesi için amaç fonksiyonları kullanılır. Belirlenen büyüklükte hata miktarına ulaşıldığında veya istenilen sayıda iterasyon yapıldığında algoritma eğitim işlemi durdurur. En çok kullanılan eğitim işlemi ileri beslemeli geri yayılmalı sinir ağları algoritmasıdır. Hatanın azaltılması işlemi gradyan azaltma yöntemi kullanılarak gerçekleştirilir. Eğitim işlemi sonunda elde edilen ağırlıklar vasıtasıyla test işlemi gerçekleştirilir ve tahminleme işlemi sonlandırılır. Bu hali ile çalışan YSA modeli Çok Katmanlı YSA modeline örnektir ve öğrenme parametresi, momentum oranı ve gizli nöron sayısı gibi hiperparametreler içermektedir. Bu parametreler işlem süresi ve kesinliğini etkilemekle birlikte öğrenme oranı parametresi 0.05, momentum oranı parametresi 0.1 seçilmiştir. Gizli nöron sayısı ise 3-20 arasında değişen değerlerde deneme yanılma yolu ile 8 olarak belirlenmiştir.

### 2.3.2. Dalgacık Dönüşümü

Dalgacık dönüşümü, zaman serisi modellemesindeki bazı eksikliklerin üstesinden gelmek ve Fourier dönüşümüne bir alternatif olmak için geliştirilmiştir. Fourier dönüşümü, trigonometrik sinüs-kosinüs fonksiyonlarını kullanarak verileri incelemektedir. Sinüzoidal fonksiyonların nispeten kolay tahmin edilebilir fonksiyonlar olduğu iyi bilinmektedir. Düzensiz ve asimetrik bir sinyalin sinüzoidal fonksiyonlarla ifade edilmesi sadece sinyalin doğasına aykırı olmakla kalmamakta, aynı zamanda sinyalin birçok özelliğinin kaybolmasına da neden olmaktadır. Ancak dalgacık dönüşümü yöntemi ile orijinal veri seti ardışık veri setlerine dönüştürülmektedir. Bu dönüştürme sırasında orijinal verilerdeki tüm özellikler tam olarak ardışık verilere taşınmaktadır. Bu sayede orijinal verilerdeki özelliklerin ön plana çıkması sağlanıp, daha uygun modelleme yapılarak doğru tahminler sağlanmaktadır. Dalgacık dönüşümünde ana dalga boyu belirli bir ölçek ve zamanda kaydırılarak, karmaşık veri seti özelliklerini kaybetmeden basit fonksiyonlara dönüştürülmektedir (Başakın vd., 2022: 789-790).

Ana dalgacık olarak da adlandırılan orijinal dalgacığın ailesinden bağımsız olarak kaydırılmış ve ölçeklenmiş versiyonları denklem (1)'deki şekilde tanımlanabilmektedir.

$$\int_{-\infty}^{+\infty} \varphi(t) dt = 0 \quad (1)$$

Bu özelliği sağlayan her  $\varphi(t)$  fonksiyonu bir dalgacık olarak ifade edilmektedir.

Dalgacık ayrıştırması ile farklı büyüklükte pencereler üretilmekte ve sinyal çeşitli bölgelere ayrılarak analiz edilmektedir. Böylece dalgacık analizi, uzun zaman aralığında düşük frekans bilgisi ile birlikte kısa zaman aralığında yüksek frekans bilgisinin belirlenmesini sağlamaktadır. Bu nedenle analiz sonucu tek boyutlu çizgiler yerine bölgelerle belirtilmektedir.

Dalgacık dönüşümü alanında sürekli ve ayrık olmak üzere iki farklı dönüştürme tekniği bulunmaktadır.

Ayrık dalgacık dönüşümünde, orijinal sinyale iki tip filtre uygulanmaktadır. Birinci filtre, sinyalin trendini, ikinci filtre trendin sapmalarını yakalamaktadır. Ayrık dalgacık dönüşümü için denklem (2)'de "W" dalgacık fonksiyonu, ilk filtreler "A" ve "D" sırasıyla ölçeği ve dönüşümü temsil etmektedir. Bu durumda, ayrıştırmanın ilk aşamasında elde edilen;

$$W = A_1 + D_1 \quad (2)$$

burada  $A_1$  ve  $D_1$ , sırasıyla sinyalin düşük frekansı ve sinyalin yüksek frekansı olarak gösterilmektedir. Bu ayırma sonraki seviyeler için yapılmakta ve istenilen çözünürlük elde edilene kadar devam etmektedir.

$$W = A_n + \sum_{i=1}^n D_i \quad (3)$$

Ek olarak, ölçekler ve konumlar, herhangi bir t anında ikili ve ayrık zaman serisinin kuvvetlerine dayanmaktadır:

$$DWT_{\varphi} f(j, k) = a_0^{-j} \int \varphi(a_0^j t - kb_0) f(t) dt \quad (4)$$

burada  $a$  ve  $b$  sırasıyla genişleme ve zaman faktörlerini.  $R$ , gerçek sayılar alanını ve  $j, k$  tam sayıları temsil etmektedir. Pratik amaçlar için en verimli durumu sağladığı için ikili sistem düzeni ( $a_0=2; b_0=1$ ) uygulanmaktadır.

$$DWT_{\varphi}f(j, k) = 2^{-\frac{j}{2}} \int \varphi(2^{-j}t - k)f(t)dt \quad (5)$$

$DWT_{\varphi}f(j, k)$  ile, frekans alanındaki ve zaman alanındaki orijinal zaman serisinin özellikleri aynı anda yansıtılır.

### 2.3.3. Performans Değerlendirme Kriterleri

Belirli performans kriterlerine göre değerlendirilen makine öğrenme yöntemlerinin istatistiki olarak değerlendirilmesi önem arz etmektedir. Bu çalışmada yapılan tahmin modelleri için performans değerlendirmesinde sırasıyla hata kareleri ortalamasının karekökü ( $HKOK$ ) ve belirleme katsayısı ( $R^2$ ) dikkate alınmıştır. Kullanılan performans kriterleri denklem (6), (7), (8) ve (9)'da şu şekilde hesaplanmıştır:

$$HKOK = \sqrt{\frac{1}{n} \sum_{i=1}^n (FSE_{pi} - FSE_{oi})^2} \quad (6)$$

$$R^2 = 1 - \frac{\text{Regresyon Kareler Toplamı (RKT)}}{\text{Genel Kareler Toplamı (GKT)}} \quad (7)$$

$$RKT = \sum (FSE_{ti} - FSE_0)^2 \quad (8)$$

$$GKT = \sum (FSE_{gi} - FSE_0)^2 \quad (9)$$

Denklem (6) ve (7)'de  $FSE$ , finansal stres endeksini,  $n$ , toplam gözlem ve tahmin değeri sayısını;  $FSE_{ti}$ ,  $i$ . verim tahmin değerini;  $FSE_{gi}$ ,  $i$ . gerçek verim değerini;  $FSE_0$ , gerçek verim değerleri ortalamasını ifade etmektedir.

## 3. Bulgular

Bu çalışma, finansal stres endeksi serilerinin kapsamlı bir analizini sağlamak ve yalnızca YSA ile değil, aynı zamanda DD-YSA yöntemini de içeren uygulamalarından oluşmaktadır. Literatürdeki çalışmalar incelendiğinde, optimum gecikme uzunluklarının belirlenmesinin zaman serisi tahminlerinde temel unsurlardan biri olduğu görülmektedir. Bu anlamda orijinal serilerle ilişkili gecikmeleri tespit etmek için otokorelasyon fonksiyonları oluşturulmuş ve gecikme sayısını belirlemek için otokorelasyon fonksiyonları tarafından elde edilen farklı gecikme uzunlukları dikkate alınarak YSA modeli uygulanmıştır. YSA ilk olarak finansal stres endeksi zaman serilerini tahmin etmek için geliştirilmiştir. İkinci olarak, dalgacık ayrıştırması yaygın olarak kullanılan ön işleme yöntemlerinden biri olduğu için tahmin doğruluklarını iyileştirmek için bağımsız modellere dahil edilmiştir. Bunun için DD-YSA kullanılmış ve en iyi model performansına ulaşmak için farklı dalgacık türleri ve ayrıştırma seviyeleri değerlendirilmiştir. Tüm modellerin doğruluğu,  $HKOK$  (hata karelerinin ortalamasının karekökü) ve  $R^2$  gibi performans ölçütlerine göre değerlendirilmiştir. Ayrıca, oluşturulan modellerin karşılıklı karşılaştırmasını sağlamak için band ve saçılma grafikleri sunulmuştur.

### 3.1. Oto Korelasyon ile Optimum Gecikme Uzunluklarını Tanımlama

Zaman serisi tahminlerinde optimum gecikme uzunluklarının belirlenmesi büyük önem taşımaktadır. Gecikme uzunluğunun büyüklüğü, mevcut araştırmadaki oto korelasyona göre belirlenmiştir. Oto korelasyon, zamana bağlı bir değişkenin  $t$  zamanındaki değerinin  $t-n$  veya  $n$ . gecikme uzunluğu değerlerinden etkilenmesi durumunu ifade etmektedir. Trend giderme ve gecikme uzunluklarını elde etme uygulamalarında oto korelasyondan faydalanılabilmektedir (Aghelpour vd., 2019:1473). Gecikme uzunluğu -1, gecikme uzunluğu -2 ve gecikme uzunluğu -3'ün finansal stres endeksi tahmini üzerinde olumlu etkisi olup olmadığı konusunda YSA ve dalgacık dönüşümlü-YSA yöntemi temel alınarak belirlenmiştir. Böylece oto korelasyon sonuçları valide edilmiş ve gecikme sayısı üç olarak belirlenmiştir.

### 3.2. YSA Model Sonuçları

Tahminlerde bağımsız model performansını değerlendirmek için St Louis Financial Stress Index verilerine YSA ve DD-YSA uygulanmıştır. YSA ve DD-YSA yapılarına ilişkin ayrıntılar devamında vurgulanırken, parametreler sırasıyla Tablo 1 ve 2'de sunulmaktadır. Sinir ağlarında ileri beslemeli


geri yayılım ve öğrenme makineleri gibi çeşitli yapıların olduğu iyi bilinmektedir. Bu çalışmada, finansal stres endeksi tahminleri için ileri beslemeli geri yayılım kullanılmıştır. Model yapısı bir girdi katmanı, bir gizli katman ve bir çıktı katmanından oluşmaktadır. Gizli katmanda kullanılan nöron sayısı deneme-yanılma yöntemiyle belirlenmiş olup, nöron sayısı için toplamda 3 ila 20 deneme yapılmıştır. Aktivasyon fonksiyonu olarak gizli katmanlarda tanjant hiperbolik fonksiyon ve çıkış katmanlarında sigmoid fonksiyon kullanılmıştır. Eğitim için Broyden-Fletcher-Goldfarb-Shanno algoritması kullanılmış ve iterasyon sayısı 1000 olarak belirlenmiştir.

İleriye dönük tahminlerde performans değerleri t, t-1 ve t-2 haftalık YSA modeli için HKOK= 0,29 ve R<sup>2</sup>= 0,85 olarak elde edilmiştir. YSA performansının istatistiksel olarak yeterli olduğu Tablo 1’de gösterilmiştir.

**Tablo 1. İstatistiksel Göstergeler Açısından YSA Modeli Bulguları**

Model	Girdi Kombinasyonu	Çıktı	Test	
			HKOK	R <sup>2</sup>
YSA	t, t-1, t-2	t+1	0,29	0,85

YSA modelinde maksimum etkileşim derecesi deneme yanılma ile belirlenmiştir. R<sup>2</sup> değeri için saçılma grafiğinin çizilmesi optimum modeli belirlemek için yarar sağlamaktadır. Saçılma grafiği Şekil 2’de gösterilmiştir.



**Şekil 2. Test Seti için YSA Yönteminin Saçılma Grafiği**

Şekil 2, YSA modeli çıktıların t+1 tahmini için 1:1 mükemmel çizgiyle YSA modelinin uyumlu olduğunu açıkça ortaya koymuştur. Saçılma grafiğine göre t+1 tahmininde tahmin edilen ve gerçekleşen finansal stres endeksi arasında yüksek korelasyon bulunmaktadır.

### **3.3. Dalgacık Dönüşümlü-YSA Model Sonuçları**

Literatürde pek çok çalışma bulunmasına rağmen her zaman serisine uygun evrensel bir dalgacık tipi yer almamaktadır. Bu nedenle, ana dalgacık seçim kurallarının eksikliği göz önüne alındığında, optimal dalgacık tipinin belirlenmesinde zorluk yaşanmaktadır. Bu çalışmada Haar



dalgacıkları, Daubechies dalgacıkları, Symlets dalgacıkları ve Coiflet dalgacıkları olmak üzere dört farklı dalgacık türü kullanılmış ve gözlemlerle en iyi uyumu sağlayan dalgacık türü seçilmiştir. Ayrıca, optimum ayrıştırma seviyesini belirlemek için her bir ana dalgacık için üç ile yedi seviye denenmiştir. Bu işlem için, bağımsız modellerin tahmini için YSA yapısının önceden belirlenmiş olduğu YSA modeli kullanılmıştır. Tablo 2’de, test setleriyle ilgili olarak dalgacık ve ayrıştırma seviyesi için HKOK ve R<sup>2</sup> değeri belirtilmiştir. Sonuçlar, en yüksek doğruluğun Coiflet dalgacıkları kullanılarak elde edildiğini, bunu sırasıyla Symlets dalgacıkları ve Daubechies dalgacıklarının sırasıyla rank 2 ve rank 3 olarak izlediğini göstermiştir. En düşük doğruluk ise Haar dalgacıkları kullanılarak elde edilmiştir. Coiflet dalgacıkları için gerçekleştirilen farklı ayrıştırma seviyeleri arasında en iyi sonuçlar altı seviyede sağlanmıştır.


Elde edilen sonuçlara göre, DD-YSA modelinin bağımsız modellerin performansında artışa yol açtığı görülmektedir.




İleriye dönük tahminlerde performans değerleri t, t-1 ve t-2 haftalık DD-YSA modeli için HKOK= 0,12 ve R<sup>2</sup>= 0,96 olarak elde edilmiştir. DD-YSA performansının istatistiksel olarak yeterli olduğu Tablo 2’de gösterilmiştir.

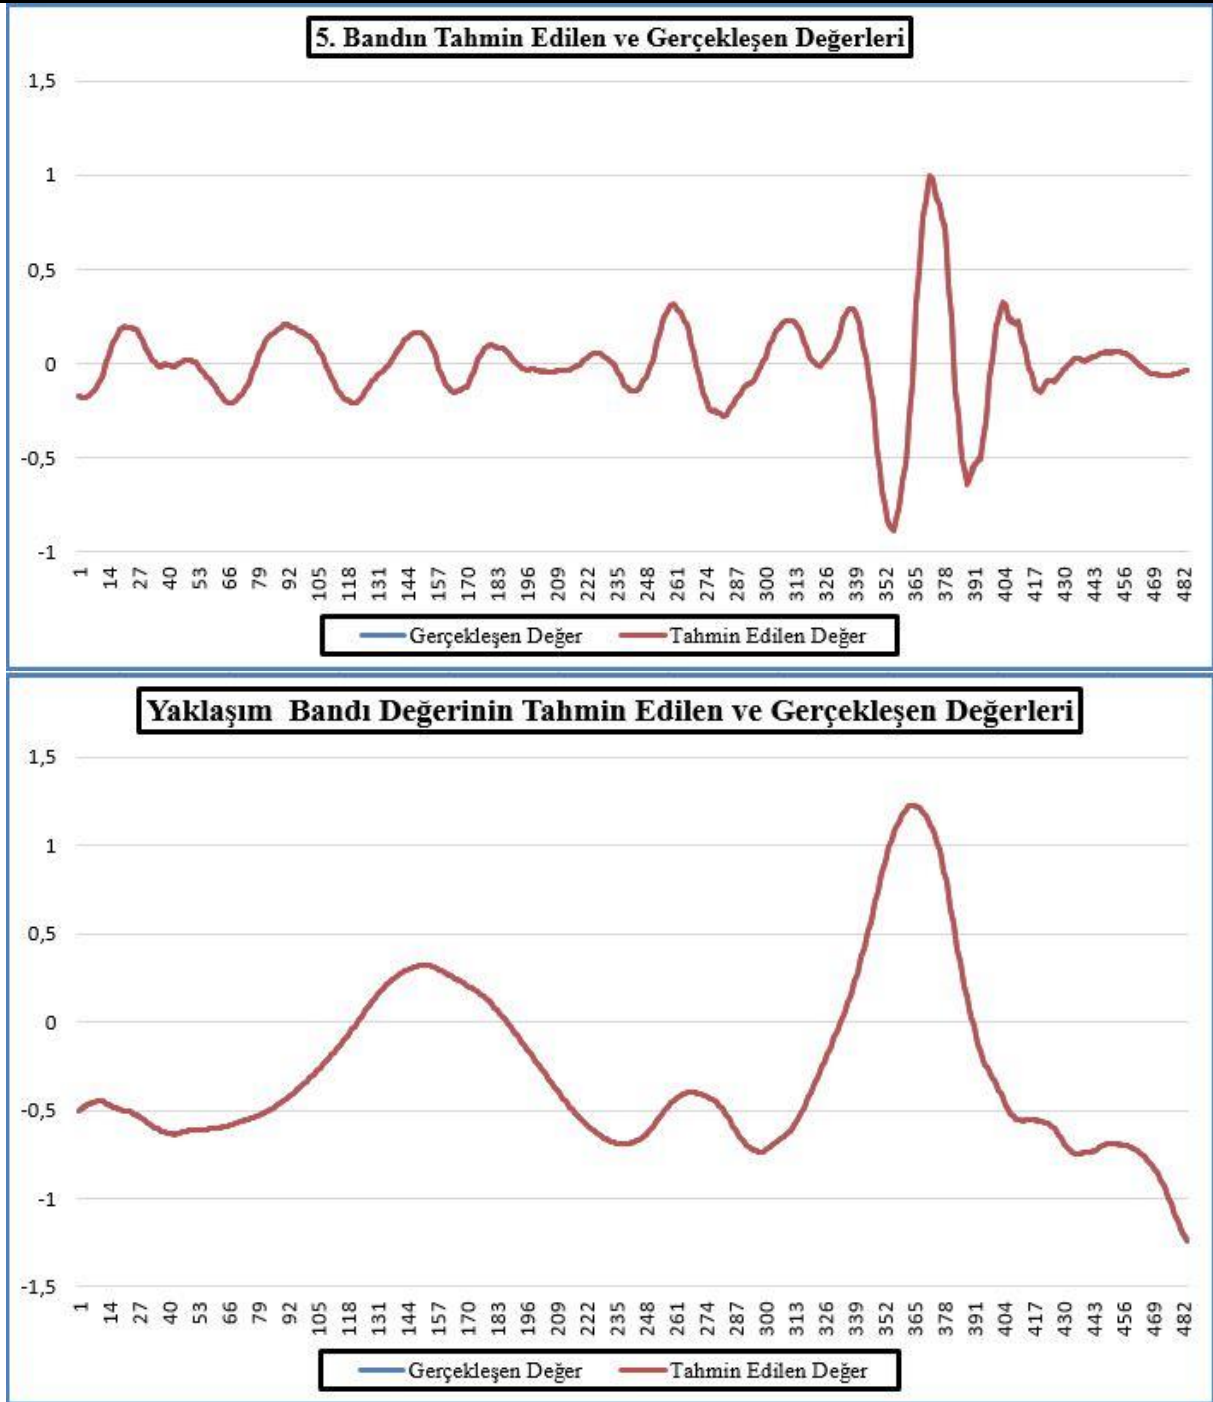
**Tablo 2. İstatistiksel Göstergeler Açısından DD-YSA Modeli Bulguları**

Model	Girdi Kombinasyonu	Çıktı	Test	
			HKOK	R <sup>2</sup>
DD-YSA	t, t-1, t-2	t+1	0,12	0,96

DD-YSA modelinde maksimum etkileşim derecesi deneme yanılma ile belirlenmiştir. R<sup>2</sup> değeri için saçılma grafiğinin çizilmesi optimum modeli belirlemek için yarar sağlamaktadır. Tahminler için elde edilen sonuçların saçılma grafiği Şekil 4’te gösterilmiştir. Coiflet dalgacıkları tarafından türetilen orijinal seriler ve alt bantlar Şekil 3’te gösterilmektedir.

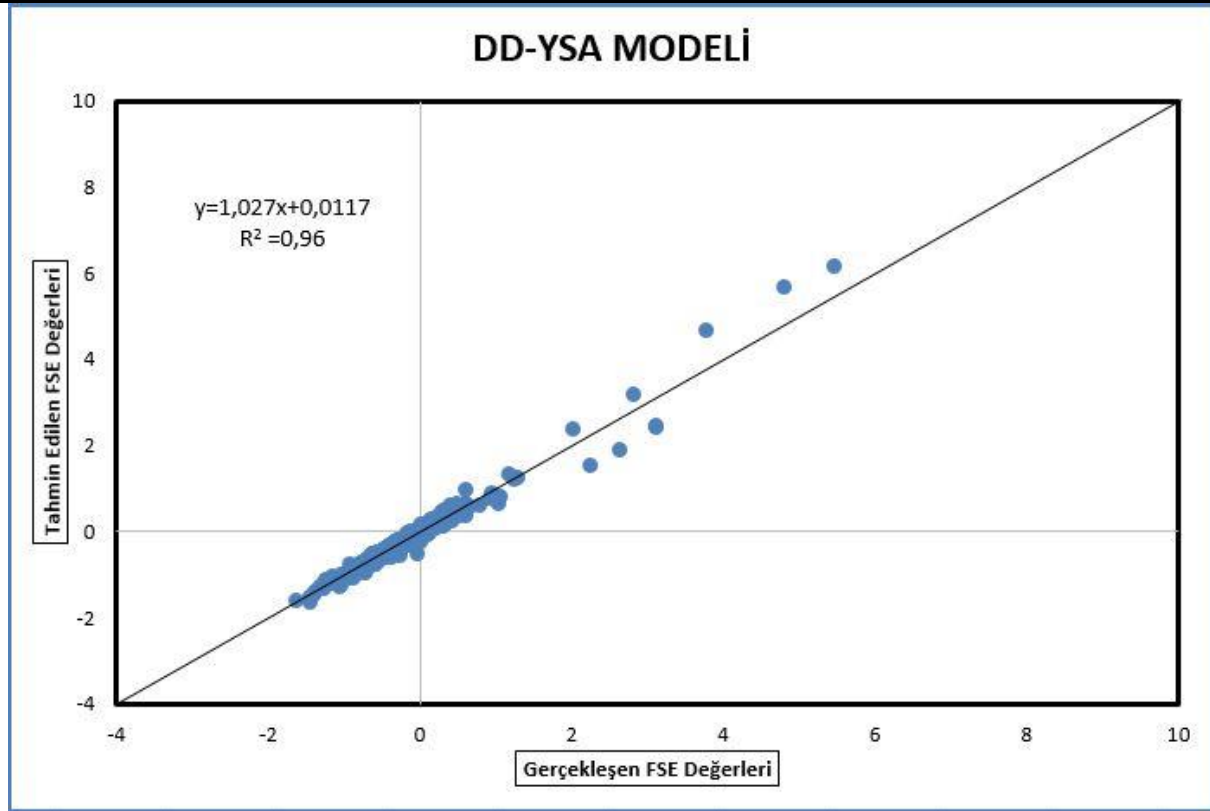






Şekil 3. Coiflet Dalgacıkları Tarafından Ayrıştırılan Alt Bantlar

Finansal stres endeksinin gerçekleşen değerleri mavi çizgi, tahmin edilen değerleri kırmızı çizgi ile temsil edilmektedir.



Şekil 4. Test Seti için DD-YSA Yönteminin Saçılma Grafiği

Şekil 4, DD-YSA modeli çıktılarının t+1 tahmini için 1:1 mükemmel çizgiyle YSA modelinden daha uyumlu olduğunu açıkça ortaya koymuştur. Saçılma grafiğine göre t+1 tahmininde tahmin edilen ve gerçekleşen finansal stres endeksi arasında YSA yöntemi ile elde edilen korelasyondan daha yüksek korelasyon bulunmaktadır. Bu bulgunun ilgili literatürle uyumlu olduğunu özellikle belirtmekte fayda bulunmaktadır. Öyle ki Arslan ve Ertuğrul (2022) çalışmalarında YSA'yı kullanarak gerçekleştirdikleri analizde modellerin kendi aralarında karşılaştırılabilmesi için saçılma grafiklerine yer vermişlerdir. İstatistiksel bilgilere ek olarak, daha iyi bir genel bakış sunmak için grafik ve diyagramlar üretmek önemli ölçüde yarar sağlamaktadır.

### Sonuç ve Değerlendirme

Küresel finansal piyasalarda yaşanan gelişmelerle birlikte artan beklenti ve belirsizlikler kontrol edilemeyen finansal davranışları beraberinde getirmektedir. Finansal sistem içerisinde farklı şekillerde gerçekleşen hareketleri takip edebilmek ve tahmin edebilmek, finansal aktörler için büyük önem arz etmektedir. Bu bağlamda farklı finansal göstergelerin dikkate alınması ve anlaşılması için bir takım istatistiksel endeksler oluşturulmaktadır. Söz konusu endekslerden biri de finansal stresi ölçebilmek için hazırlanan finansal stres endeksidir.

Bu çalışmada finansal stres endeksini tahmin etmek için makine öğrenme yöntemleri uygulanmıştır. İki farklı makine öğrenme yönteminin (YSA ve DD-YSA) tahmin sonuçları karşılaştırıldığında DD-YSA yönteminin daha iyi performans gösterdiği görülmektedir.

Çalışma sonucunda, finansal stres endeksinin ölçülmesi ve tahmin edilmesinde makine öğrenme yöntemlerinin geleneksel yöntemlere iyi bir alternatif olduğu ortaya konularak, literatüre katkı sağlanabileceği öngörülmektedir. Belirsizlik hakkında bilgi sahibi olmak ve riskten korunmak isteyen yatırımcı aktörlerin finansal stres endeksi tahminlerini doğrulama aracı olarak kullanılabileceği düşünülmektedir. Finansal gösterge niteliğine sahip olan farklı endeksler ile yapılabilecek tahminler finansal piyasalardan haberdar olmak isteyen aktörlere fayda sağlayabilir.

Bu çalışmada elde edilen etkili sonuçlara rağmen, dikkate alınması gereken bazı sınırlamalar bulunmaktadır. Haftalık finansal stres endeksi zaman serileri ile yapılan tahminler finansal karar vermede faydalı olsa da günlük veya aylık serilerle yapılan tahminlerin sonuçları araştırmalar

açısından daha avantajlı olabilir. Finansal stres endeksi ile yapılacak tahminlerde farklı değişken ve makine öğrenmesi yöntemlerinden yararlanılabilir. Ayrıca, gelecekte yapılacak çalışmaların sonuçları, makine öğrenmesi yöntemleri ile sınırlı olan bu çalışmanın sonuçlarıyla karşılaştırılarak finansal stres endeksi serilerine uyarlanabilir.

### Kaynakça

- Aghelpour, P., Mohammadi, B., & Biazar, S. M. (2019). Long-term monthly average temperature forecasting in some climate types of Iran, using the models SARIMA, SVR, and SVR-FA. *Theoretical and Applied Climatology*, 138(3), 1471-1480.
- Akay, E. Ç., Topal, K. H., Kizilarlan, S. & Bulbul, H. (2019). Forecasting of Turkish housing price index: ARIMA, random forest, ARIMA-random forest. *Pressacademia*, 10(10), 7-11.
- Aker, Y. (2012). Analysis of Price Volatility in BIST 100 Index With Time Series: Comparison of Fbprophet and LSTM Model. *Avrupa Bilim ve Teknoloji Dergisi*, (35), 89-93.
- Aksoy, B. (2021). Pay senedi fiyat yönünün makine öğrenmesi yöntemleri ile tahmini: Borsa İstanbul örneği. *Business and Economics Research Journal*, 12(1), 89-110.
- Alsü, E. (2020). Finansal Stres Endeksi İle Doğrudan Yabancı Yatırımlar, Portföy Yatırımları Ve Dış Borç Stoku Arasındaki İlişki: ARDL Sınır Testi. *ETÜ Sentez İktisadi ve İdari Bilimler Dergisi*, (1), 27-40.
- 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.
- Ayala, J., García-Torres, M., Noguera, J. L. V., Gómez-Vela, F. & Divina, F. (2021). Technical analysis strategy optimization using a machine learning approach in stock market indices. *Knowledge-Based Systems*, 225, 107119.
- Aygören, H., Sarıtaş, H. & Morali, T. (2012). İMKB 100 endeksinin yapay sinir ağı ve newton nümerik arama modelleri ile tahmini. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 4(1), 73-88.
- Balakrishnan, R., Dysainger, S., Tytell, I. & Elekdag, S. A. (2009). The transmission of financial stress from advanced to emerging economies. *Emerging Markets Finance and Trade*, 47(sup2), 40-68.
- Balakrishnan, R., Dysainger, S., Elekdag, S. & Tytell, I. (2011). The transmission of financial stress from advanced to emerging economies. *Emerging Markets Finance and Trade*, 47(sup2), 40-68.
- Başakın, E. E., Ekmekcioğlu, Ö., Çıtakoğlu, H. & Özger, M. (2022). A new insight to the wind speed forecasting: robust multi-stage ensemble soft computing approach based on pre-processing uncertainty assessment. *Neural Computing and Applications*, 34(1), 783-812.
- Bueno, S., & Salmeron, J. L. (2009). Benchmarking main activation functions in fuzzy cognitive maps. *Expert systems with Applications*, 36(3), 5221-5229.
- Bülbül, H. & Akgül, I. (2018). Türkiye Finansal Stres Endeksi ve Markov Rejim Değişim Modeli ile Yüksek Stres Dönemlerinin Belirlenmesi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 13(3), 125-140.
- Cardarelli, R., Elekdag, S. & Lall, S. (2011). Financial stress and economic contractions. *Journal of Financial Stability*, 7(2), 78-97.
- Çamlıca, F. & Gunes, D. (2016). Türkiye'de Finansal Stresin ölçülmesi: Yöntemsel Bir Karşılaştırma (No. 1606). Research and Monetary Policy Department, Central Bank of the Republic of Turkey.
- Dingli, A. & Fournier, K. S. (2017). Financial time series forecasting-a deep learning approach. *International Journal of Machine Learning and Computing*, 7(5), 118-122.
- Ebadati, O. M. E. & Mortazavi, M. T. (2018). An efficient hybrid machine learning method for time series stock market forecasting. *Neural Network World*, 28(1), 41-55.
- Ekinci, A. (2013). Financial stress index for Turkey. *Doğuş Üniversitesi Dergisi*, 14(2), 213-229.
- FRED, Federal Reserve Bank of St. Louis, St. Louis Fed Financial Stress Index (DISCONTINUED) [STLFSI2], retrieved from FRED, Federal Reserve Bank of St. Louis; <https://fred.stlouisfed.org/series/STLFSI2>, July, 2022.

- Ghazanfar, M. A., Alahmari, S. A., Aldhafiri, Y. F., Mustaqem, A., Maqsood, M., & Azam, M. A. (2017). Using machine learning classifiers to predict stock exchange index. *International Journal of Machine Learning and Computing*, 7(2), 24-29.
- Hakkio, C. S. & Keeton, W. R. (2009). Financial stress: What is it, how can it be measured, and why does it matter. *Economic Review*, 94(2), 5-50.
- Hoque, M. E. & Low, S. W. (2022). Reactions of Bitcoin and Gold to Categorical Financial Stress: New Evidence from Quantile Estimation. *Risks*, 10(7), 136.
- Karacan, S. & Kırdar, M. (2021). Hisse Senedi Fiyat Tahmininde Makine Öğrenmesi ve Yapay Zeka Kullanımı. *Journal of International Social Research*, 14(76).
- Kartal, C. (2020). Destek Vektör Makineleri ile Borsa Endekslerinin Tahmini. *Itobiad: Journal of The Human & Social Science Researches*, 9(2).
- Kaya, E. & Kılınç, A. (2017). Türkiye için Finansal Sıkıntı Endeksinin Ölçümü ve Finansal Sıkıntı Endeksinin Reel Ekonomik Faaliyetler İle İlişkisi. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(1), 57-70.
- Kaynar, T., & Yiğit, Ö. E. (2021). Öznitelik Mühendisliği ile Makine Öğrenmesi Yöntemleri Kullanılarak BIST 100 Endeksi Değişiminin Tahminine Yönelik Bir Yaklaşım. *Yaşar Üniversitesi E-Dergisi*, 16(64), 1741-1762.
- Duprey, T. & Klaus, B. (2017). How to Predict Financial Stress? An Assessment of Markov Switching Models (No. 2017-32). Bank of Canada.
- Illing, M., & Liu, Y. (2006). Measuring financial stress in a developed country: An application to Canada. *Journal of Financial Stability*, 2(3), 243-265.
- Luo, J., Chen, H., Xu, Y., Huang, H. & Zhao, X. (2018). An improved grasshopper optimization algorithm with application to financial stress prediction. *Applied Mathematical Modelling*, 64, 654-668.
- Monin, P. J. (2019). The OFR financial stress index. *Risks*, 7(1), 25.
- Pabuçcu, H. (2019). Borsa Endeksi Hareketlerinin Makine Öğrenme Algoritmaları İle Tahmini. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, (23), 179-190.
- Panchal, G., Ganatra, A., Kosta, Y. P. & Panchal, D. (2011). Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers. *International Journal of Computer Theory and Engineering*, 3(2), 332-337.
- Parray, I. R., Khurana, S. S., Kumar, M. & Altalbe, A. A. (2020). Time series data analysis of stock price movement using machine learning techniques. *Soft Computing*, 24(21), 16509-16517.
- Patel, J., Shah, S., Thakkar, P. & Kotecha, K. (2015). Predicting stock market index using fusion of machine learning techniques. *Expert Systems with Applications*, 42(4), 2162-2172.
- Polat, O. (2021). Petrol Fiyat Şokları ve Finansal Stres Arasındaki Zaman-Değişimli İlişki: AB Bölgesi İçin TVP-VAR Analizi. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 13(25), 689-702.
- Sandahl, J. F., Holmfeldt, M., Rydén, A. & Strömqvist, M. (2011). An index of financial stress for Sweden. *S v ER ig ESR ik S bank*, 2.
- Slingenberg, J. W. & De Haan, J. (2011). Forecasting financial stress. *DNB Working Paper*, No. 292/April.
- Vdovychenko, A. & Oros, G. (2015). Financial stress index: estimation and application in empirical researches in Ukraine. *Financial and Banking Services Market*, Vol. 14 (No2).
- Yiğiter, Ş. Y., Sarı, S. S. & Başakın, E. E. (2017). Hisse senedi kapanış fiyatlarının yapay sinir ağı ve bulanık mantık çıkarım sistemleri ile tahmin edilmesi.
- Xiong, X., Liu, J., & Liu, Z. (2022). Can economic policy uncertainty predict financial stress? A MIDAS approach. *Applied Economics Letters*, 29(1), 22-29.

### Extended Abstract

#### Aim and Scope

It is accepted that the financial stress index has an effect on the stability in the financial markets and the changes in the real economy. Measuring or predicting the financial stress, which has an impact on the decisions to be made on financial decisions, is of critical importance for the financial

---

situation. Therefore, the main purpose of this study is to predict the financial stress index levels observed in financial markets. To achieve this goal, four main steps have been followed:

- 1) Determination of lag times used for forecasts
- 2) Decomposition of the original time series into spectral bands via wavelet transform
- 3) Making predictions through ANN and WT-ANN
- 4) Statistical measurement of the performances of the models

### **Methods**

This study was conducted by the Federal Reserve Bank of St. Louis Financial Stress Index (STLFSI) published by St. Louis. STLFSI measures the degree of financial stress in the markets. It was created from an 18-week data set of interest rate, yield spread and other indicators, all of which are weekly averages of daily data series. Each of these variables takes into account some aspects of financial stress. Accordingly, as the level of financial stress in the economy changes, there is a possibility that the data sets will move together. The average value of the STLFSI index starting in late 1993 is designed to be zero. Therefore, zero represents normal financial market conditions. Values below zero indicate below-average financial market stress, while values above zero indicate above-average financial market stress (FRED, 2022).

Federal Reserve Bank of St. Louis calculates financial parameters around the world, including the stress index. In this study, the financial stress index time series was examined. Financial stress index values recorded in weekly periods for 30 years (between December 1993 and July 2022) were used. ANN and W-ANN were used as research methods. R package program was used to implement the methods.

### **Findings**

This study provides a comprehensive analysis of financial stress index series and consists of applications not only with ANN but also with WT-ANN method. When the studies in the literature are examined, it is seen that determining the optimum lag lengths is one of the basic elements in time series predictions. In this sense, autocorrelation functions were created to determine the lags associated with the original series, and the ANN model was applied to determine the number of lags, taking into account the different lag lengths obtained by the autocorrelation functions. ANN was first developed to predict financial stress index time series. Second, because wavelet decomposition is one of the widely used preprocessing methods, it is included in the standalone models to improve their prediction accuracy. For this, WT-ANN is used and different wavelet types and decomposition levels are evaluated to achieve the best model performance. The accuracy of all models has been evaluated against performance criteria such as MSES (root mean square of error squares) and  $R^2$ . In addition, band and scatter plots are presented to provide a mutual comparison of the generated models.

### **Results**

As a result of the study, it is predicted that machine learning methods can be a good alternative to traditional methods in the measurement and prediction of the financial stress index and contribute to the literature. It is thought that investor actors who want to have information about uncertainty and hedge risk can be used as a means of verifying financial stress index predictions. Forecasts that can be made with different indices, which have the quality of financial indicators, can benefit the actors who want to be aware of the financial markets.

Despite the effective results obtained in this study, there are some limitations that should be considered. Although predictions made with weekly financial stress index time series are useful in making financial decisions, the results of predictions made with daily or monthly series may be more advantageous in terms of research. Different variables and machine learning methods can be used in the predictions to be made with the financial stress index. In addition, the results of future studies can be adapted to the financial stress index series by comparing the results of this study, which is limited to machine learning methods.