

Finans Literatüründe Makine Öğrenmesi Yöntemlerinin Kullanımı ve Uygulama Alanları

İlker Sakıncı¹

S. Öznur Sakıncı²

Özet

Bu çalışma, makine öğrenmesinin akademik finans araştırmalarında yöntemsel bir araç olarak nasıl kullanıldığını incelemektedir. Çalışmada, bu yöntemlerin finansal analizin dört temel alanında nasıl uygulandığı ele alınmaktadır. Dijitalleşme, hesaplama gücü ve yapay zekâ teknolojilerindeki gelişmelerle birlikte finansal faaliyetler önemli ölçüde değişmiştir. Önceden büyük ölçüde insan yargısına dayanan süreçler, giderek veri ve algoritmalar tarafından şekillendirilmeye başlamıştır. Bu değişim, algoritmaların finansal karar alma süreçlerinde ya bağımsız karar vericiler ya da insanlara yardımcı araçlar olarak konumlanmasına yol açmıştır.

Birinci alan, makine öğrenmesi modellerinin özellikle getiri, volatilite ve finansal risk tahmininde karmaşık ve doğrusal olmayan ilişkileri ve yüksek boyutlu veri setlerini nasıl ele aldığını incelemektedir. Bulgular, bazı durumlarda bu modellerin geleneksel doğrusal yaklaşımlardan daha iyi sonuçlar ürettiğini göstermektedir.

İkinci alan, doğal dil işleme ve metin madenciliğinin piyasa beklentilerini, yatırımcı duyarlılığını ve belirsizliği ölçmedeki rolüne odaklanmaktadır. Bu yöntemler, finansal haberleri ve dijital içerikleri analiz ederek tahmin modellerine katkı sağlamaktadır.

Üçüncü alan, portföy optimizasyonu, risk dengelemesi ve algoritmik ticarete makine öğrenmesi uygulamalarını ele almaktadır. Burada tahmin ile anlık karar alma süreçlerinin birlikte ele alınması önem taşımaktadır.

1 Doç. Dr., (Sorumlu Yazar), Ondokuz Mayıs Üniversitesi İİBE, İşletme Bölümü, ilker.sakinci@omu.edu.tr, ORCID ID: 0000-0002-9549-8563

2 Doç. Dr., Hitit Üniversitesi Sosyal Bilimler Meslek Yüksekokulu, Yönetim ve Organizasyon Bölümü, oznursakinci@gmail.com, ORCID ID: 0000-0002-0806-3263

Dördüncü alan ise anomali tespiti, dolandırıcılık analizi ve piyasa mikro yapısının incelenmesine yöneliktir. Erken aşamada olağandışı örüntülerin tespit edilmesi, risk yönetimi ve piyasa bütünlüğü açısından kritik görülmektedir.

1. Giriş

Finansal piyasalar, artan veri sayısı, hızlanan bilgi akışı ve karmaşılaşan piyasa yapıları nedeniyle geleneksel analiz yöntemlerinin sınırlarını zorlayan bir dönüşüm süreci yaşamaktadır. Özellikle dijitalleşme ve hesaplama alanındaki ilerlemeler, finans alanında kullanılan yöntemlerin niteliğini köklü biçimde değiştirmiştir. Bu bağlamda makine öğrenmesi ve ilişkili yapay zekâ teknikleri, finansal karar alma süreçlerinde yalnızca destekleyici araçlar olmaktan çıkarak, doğrudan analiz ve öngörü üretiminde merkezi bir rol üstlenmeye başlamıştır. Makine öğrenmesi yöntemleri doğrusal olmayan ilişkileri yakalama, yüksek boyutlu veri setlerini işleme ve zaman içinde değişen piyasa koşullarına uyum sağlama kapasiteleri sayesinde finansal tahmin, risk yönetimi ve portföy oluşturma kararları gibi alanlarda yaygın biçimde kullanılmaktadır. Bununla birlikte, bu yöntemlerin finansal akademik literatüründe nasıl konumlandığı, hangi problem alanlarında anlamlı katkılar sunduğu ve hangi metodolojik sınırlamalara sahip olduğu sorularının önemi giderek artmaktadır. Bu çalışma, söz konusu sorulara yanıt arayarak makine öğrenmesinin finans literatüründeki rolünü bütüncül bir çerçevede ele almaktadır.

2. Finansal Tahmin Modellerinde Makine Öğrenmesi: Getiri, Volatilite ve Risk Öngörüsü

Finansal tahmin literatüründe makine öğrenmesi (ML) yöntemlerinin yükselişi, iki ampirik gözlemle yakından ilişkilidir: (i) finansal zaman serilerinde ilişki yapılarının çoğu zaman doğrusal olmaması, etkileşimlerin ve rejim değişimlerinin güçlü olması; (ii) tahmin probleminde kullanılan açıklayıcı setlerin, özellikle firma düzeyi ve makro değişkenlerle birlikte, yüksek boyutluluğa ulaşması. Bu iki özellik, klasik doğrusal modellerin hem fonksiyonel form hem de model belirsizliği açısından kırılganlıklarını görünür kılarken, ML algoritmalarına “esnek fonksiyon yaklaşımı” ve “model karmaşıklığını veriyle dengeleme” gibi avantajlar sağlamıştır. Ampirik literatür, ML’nin finansal tahminde değerini çoğunlukla (a) örneklem dışı performans, (b) ekonomik anlamlılık (portföy getirisi, Sharpe oranı, işlem maliyeti sonrası performans), (c) istikrar ve rejim duyarlılığı üzerinden tartışmaktadır.

Getiri tahmininde ML yöntemlerinin en etkili ampirik örneklerinden biri, geniş ölçekli firma karakteristikleri ile beklenen getiri tahminini aynı çerçevede ele alan çalışmalardır. Gu, Kelly ve Xiu (2020), ABD hisse senedi piyasasında çok sayıda firma düzeyi açıklayıcı değişkeni kullanarak

doğrusal yaklaşımları (ör. düzenleştirilmiş regresyon) ve doğrusal olmayan ML yöntemlerini (ağaç tabanlı algoritmalar ve sinir ağları dahil) kapsamlı biçimde karşılaştırır. Çalışmanın ampirik önemi, ML'nin “yalnızca istatistiksel isabeti” değil, yatırım stratejilerine dönüştürüldüğünde ekonomik kazanımı da artırabileceğini göstermesidir (Gu ve diğerleri, 2020). Bu tür tasarımlarda kritik metodolojik mesele, tahmin gücünün veri-mining kaynaklı sahte bir iyileşme olup olmadığını ayırt etmektir; söz konusu çalışma, geniş model ailesi karşılaştırması ve örneklem dışı protokolleri ile bu riski azaltmaya dönük bir örnek sunar (Gu ve diğerleri, 2020).

Getiri tahmininin bir alt kolu, piyasa risk priminin ve uluslararası getirilerin öngörüsüdür. Bu bağlamda Rapach, Strauss ve Zhou'nun (2010) “tahmin kombinasyonu” yaklaşımı ML değildir ancak literatürde güçlü bir ampirik referans işlevi görmektedir. Çoklu öngörü modellerinin birleştirilmesinin, tekil doğrusal tahmin modellerine kıyasla daha istikrarlı örneklem dışı sonuçlar üretebildiğini gösterir (Rapach ve diğerleri, 2010). Bu çalışma, ML çalışmalarında sıkça tartışılan “model belirsizliği” ve “tahmin istikrarsızlığı” sorunlarını açık biçimde ortaya koyduğu için, ML'nin sağladığı artı değer in daha disiplinli kıyaslanmasına yardımcı olur. Uluslararası getiriler düzleminde Rapach ve diğerleri (2013), aylık ülke getirileri arasında öncü–ardıl (lead–lag) ilişkilerini inceleyerek ABD getirisinin çok sayıda ülke için gecikmeli öngörü gücü taşıdığını, ters yönde (diğer ülkelerden ABD'ye) benzer bir öngörü gücünün daha sınırlı olduğunu ampirik olarak göstermektedir (Rapach ve diğerleri, 2013). Bu tür bulgular, modern ML modellerinin “çapraz piyasa bilgi taşınımı” ve lead–lag yapıları yakalama kapasitesini değerlendiren çalışmalarda da sıklıkla kullanılan bir ampirik olgu seti sunar.

Derin öğrenme ve ağaç tabanlı yöntemlerin “günlük frekansta yön tahmini/ sinyal üretimi” bağlamında sınındığı ampirik çalışmalar, özellikle 2010'ların ortalarından sonra belirginleşmiştir. Krauss, Do ve Huck (2017), S&P 500 bileşenleri üzerinde gecikmeli getirilerden yararlanarak derin sinir ağları (DNN), gradyan artırmalı ağaçlar (gradient-boosted trees) ve rastgele ormanlar (random forests) gibi modellerle bir günlük ileriye dönük olasılıksal sinyaller üretir ve bunu istatistiksel arbitraj çerçevesinde değerlendirir. Çalışmanın literatüre katkısı, farklı ML ailelerinin aynı veri-üretim ortamında, ortak bir tahmin hedefiyle karşılaştırılması ve performansın yalnızca sınıflandırma isabetiyle değil, strateji getirileri üzerinden de raporlanmasıdır (Krauss ve diğerleri, 2017). Benzer şekilde Fischer ve Krauss (2018), LSTM tabanlı modellerin S&P 500 bileşenlerinde yön tahmininde “hafızasız” sınıflandırıcılara (ör. random forest, klasik DNN, lojistik regresyon) kıyasla belirli dönemlerde üstünlük sağlayabildiğini; ancak zamanla bu üstünlüğün işlem maliyetleri ve rekabet nedeniyle zayıflayabileceğini vurgular (Fischer & Krauss, 2018).

Bu tür bulgular, ML performansının “dönem bağımlı” olabileceği ve piyasa adaptasyonunun tahmin sinyallerini aşındırabileceği hipotezini ampirik zemine taşır.

Volatilite öngörüsü literatürü ML açısından iki nedenle elverişlidir. Volatilite serilerinin güçlü otokorelasyonu ve şokların asimetrik etkileri, doğrusal modellerde esneklik ihtiyacını artırır. Patton ve Sheppard (2015), gerçekleşen volatilitiyi “iyi” ve “kötü” volatilitite bileşenlerine ayırarak geleceğe dönük volatilitite tahmininin bu ayrıştırma ile güçlendirilebileceğini ve özellikle negatif sıçramaların daha kalıcı volatilitite etkileri yarattığını göstermiştir. Bu çalışma doğrudan “ML modeli” önermese de, volatilitite tahmininde özellik mühendisliği (feature construction) mantığının ampirik önemini net biçimde ifade eder; ML tabanlı volatilitite modellerinin de çoğu zaman bu tür ayrıştırmaları açıklayıcı setine dâhil ettiği görülmektedir (Patton & Sheppard, 2015). Doğrudan derin öğrenme temelli volatilitite tahminine örnek olarak Kim ve Won (2018), LSTM ile çoklu GARCH-tipi modelleri bütünleyen hibrit bir yapı kurmuş ve volatilitite tahmininde hibrit modelin tekil GARCH-tipi modellere kıyasla daha başarılı olduğunu raporlamıştır (Kim & Won, 2018). Burada ampirik mesaj, ML’nin “tamamen parametrik yapıların yerine geçmekten” ziyade, volatilitite dinamiklerindeki karmaşıklığı yakalamak için hibrit mimariler aracılığıyla geleneksel modelleri tamamlayabilmesidir.

Türkiye’de yapılan çalışmalar daha çok endeks yönü ve/veya volatilitite-temelli tahmin çerçevesinde yoğunlaşmaktadır. Kara, Boyacıoğlu ve Baykan (2011), İstanbul Menkul Kıymetler Borsası (IMKB) Ulusal 100 endeksinde günlük yön hareketini teknik göstergelerle beslenen ANN ve SVM modelleriyle tahmin eder ve iki yöntem arasında karşılaştırmalı performans raporlamışlardır. Çalışma, Türkiye verisi üzerinden ML sınıflandırma yaklaşımının erken örnekleri arasındadır (Kara ve diğerleri, 2011). Daha güncel bir örnek olarak Yiğit ve Karaköse (2021), BIST’te işlem gören İstanbul Şehir Endeksi (XSIST) için teknik göstergeleri farklı ML modellerine entegre ederek yön tahmin performansını araştırmıştır. Sonuç olarak bulgular Türkiye literatüründe “teknik gösterge + ML sınıflandırma” kombinasyonunun sürdürülebilir bir araştırma hattına dönüştüğünü göstermektedir (Yiğit & Karaköse, 2021). Volatilite odağında ise Şahin (2023), BIST-100 volatilitisini öngörmeye asimetrik GARCH modeli ile yapay sinir ağını farklı biçimlerde birleştiren hibrit yaklaşımlar kurmuştur ve hibrit tasarımların tahmin doğruluğunu artırma motivasyonunu ampirik olarak tartışmıştır (Şahin, 2023).

Bu ampirik çalışmaların ortak sonucu, ML yöntemlerinin finansal tahmin problemlerinde “tek tip” bir üstünlük iddiasından ziyade, problem türüne ve veri yapısına bağlı olarak avantaj sağladığıdır. Getiri tahmininde geniş açıklayıcı

setler ve doğrusal olmayan etkileşimler önemliyken (Gu ve diğerleri, 2020), yön tahmini ve sinyal üretiminde sınıflandırma algoritmalarının dönemselsel kârlılığının işlem maliyetleri ve rekabetle aşınabildiği görülmektedir (Fischer & Krauss, 2018; Krauss ve diğerleri, 2017). Volatilité tahmininde ise hibrit ML-ekonometrik yaklaşımlar, geleneksel modellerin kurumsallaşmış güçlü yanlarını (ör. koşullu varyans dinamiği) korurken, ML'nin esnek örüntü yakalama kabiliyetini devreye sokmaktadır (Kim & Won, 2018; Şahin, 2023). Bu nedenle, yöntem kısmında literatürü özetlerken yalnızca “tahmin hatası” raporlamak yerine, örneklem dışı protokolün tasarımı, rejim kırılmaları, işlem maliyetleri ve ekonomik anlamlılık gibi ölçütleri birlikte değerlendiren ampirik çalışmalar dikkate alınmalıdır (Gu ve diğerleri, 2020; Fischer & Krauss, 2018).

3. Finansal Metin Madenciliği ve Doğal Dil İşleme

Finansal piyasalarda fiyat oluşumunun yalnızca sayısal verilere değil, aynı zamanda bilgi akışına ve bu bilginin yatırımcılar tarafından nasıl algılandığına bağlı olduğu uzun süredir bilinmektedir. Bu bağlamda, yazılı metinlerin nicel hale getirilmesi ve finansal tahmin modellerine entegre edilmesi fikri, doğal dil işleme (NLP) yöntemlerinin gelişimiyle birlikte ampirik olarak test edilebilir hale gelmiştir. Finans literatüründe NLP tabanlı tahmin çalışmaları ağırlıklı olarak üç ana eksenle yoğunlaşmaktadır: (i) haber ve medya metinlerinden türetilen duyarlılık ölçümlerinin getiri tahmini, (ii) belirsizlik ve olumsuzluk içeriğinin volatilité ve risk göstergeleriyle ilişkisi, (iii) metin temelli sinyallerin geleneksel finansal değişkenleri tamamlayıcı rolü.

Bu literatürün ampirik başlangıç noktası olarak sıklıkla Tetlock (2007) gösterilmektedir. Tetlock, Wall Street Journal'ın “Abreast of the Market” köşesindeki haber metinlerini kullanarak olumsuz duyarlılık ölçütleri üretmiş ve bu ölçütlerin hem piyasa getirileri hem de işlem hacmi üzerinde anlamlı öngörü gücüne sahip olduğunu ampirik olarak göstermiştir. Çalışmanın temel katkısı, haber dilindeki olumsuz tonun kısa vadede negatif getiri ile daha uzun vadede ise fiyatların kısmen düzeltildiği bir yapı ile ilişkili olduğunu ortaya koymasıdır (Tetlock, 2007). Bu bulgu, metin tabanlı değişkenlerin yalnızca eşanlı korelasyonlar üretmediğini, aynı zamanda zamansal tahmin gücü taşıdığını göstermesi açısından önemlidir.

Tetlock'un yaklaşımı daha sonra firma düzeyine indirgenmiş ve metinlerin içerik analizi daha ayrıntılı biçimde ele alınmıştır. Tetlock, Saar-Tsechansky ve Macassasy (2008), haber metinlerinde geçen olumsuz kelimelerin firma kâr duyuruları sonrasındaki fiyat tepkilerini öngörmeye anlamlı rol oynadığını göstermiştir. Özellikle, haberlerdeki negatif tonun, kamuya açıklanan muhasebe bilgilerinin ötesinde ek bilgi içerdiği ve piyasanın bu bilgiyi fiyatlara gecikmeli

olarak yansıttığı bulunmuştur. Bu çalışma, NLP tabanlı metin değişkenlerinin finansal açıklamalarla etkileşim içinde değerlendirilmesi gerektiğini ampirik olarak ortaya koymaktadır (Tetlock ve diğerleri, 2008).

Finansal metinlerin analizinde sözlük temelli yaklaşımların sınırları, Loughran ve McDonald (2011) tarafından sistematik biçimde gösterilmiştir. Yazarlar, genel amaçlı duyarlılık sözlüklerinin (örneğin Harvard IV) finansal metinler için ciddi ölçüm hataları ürettiğini ampirik olarak belgeleyerek, finans literatürüne özgü bir kelime sözlüğü geliştirmiştir. 10-K raporları üzerinde yapılan analizler, “olumsuzluk”, “belirsizlik” ve “hukuki risk” içeren kelimelerin hisse senedi getirileri, volatilité ve işlem hacmiyle anlamlı ilişkiler taşıdığını göstermektedir (Loughran & McDonald, 2011). Bu çalışma, finansal NLP literatüründe metodolojik bir dönüm noktası olup, sonraki ampirik araştırmalar için standart bir referans haline gelmiştir.

Haber metinlerinin yanı sıra, geniş kapsamlı medya akışı kullanılarak piyasa hareketlerinin tahmin edilmesi de ampirik olarak incelenmiştir. Engelberg ve Parsons (2011), yerel gazete haberlerinin işlem hacmi üzerindeki etkisini analiz ederek, bilginin coğrafi yayılım hızının piyasa tepkilerini şekillendirdiğini göstermiştir. Bu bulgu, metnin yalnızca içeriğinin değil, erişim ve yayılım dinamiklerinin de tahmin açısından önemli olduğunu ortaya koymaktadır. Benzer biçimde, Fang ve Peress (2009), medyada yer almayan firmaların daha yüksek beklenen getiri sunduğunu, bunun da bilgi görünürlüğüyle ilişkili bir risk primi oluşturduğunu ampirik olarak belgelemiştir.

Metin tabanlı değişkenlerin volatilité ve risk tahmini bağlamındaki rolü, özellikle belirsizlik kavramı üzerinden ele alınmıştır. Baker, Bloom ve Davis (2016) tarafından geliştirilen Ekonomik Politika Belirsizliği (EPU) endeksi, gazetelerde yer alan belirli kelime kombinasyonlarına dayalı olarak oluşturulmuş ve makroekonomik belirsizlik ile finansal piyasa oynaklığı arasındaki güçlü ilişkiyi ampirik olarak göstermiştir. EPU endeksi, hem hisse senedi volatilitesi hem de yatırım kararları üzerinde anlamlı etkilere sahiptir (Baker ve diğerleri, 2016). Bu çalışma, NLP temelli göstergelerin yalnızca mikro düzeyde değil, makro-finance risk ölçümü açısından da kullanılabileceğini ortaya koymuştur.

Metin temelli risk ölçümüne ilişkin doğrulanabilir ve etkili ampirik örneklerden biri, haber arşivlerinden türetilen belirsizlik göstergelerinin ileriye dönük risk primleriyle ilişkilendirilmesidir. Manela ve Moreira (2017), Wall Street Journal’ın birinci sayfa haberlerinden türetilen **news implied volatility (NVIX)** göstergesini inşa ederek, NVIX’in tarihsel olarak kriz, savaş ve yüksek politika belirsizliği dönemlerinde keskin biçimde yükseldiğini; ayrıca NVIX’in yükseldiği dönemleri izleyen periyotlarda hisse senedi getirilerinin ortalama olarak daha yüksek seyrettiğini (risk primi kanalıyla) ampirik olarak

göstermiştir. Bu bulgu, metin tabanlı belirsizlik/riske ilişkin sinyallerin yalnızca eşanlı piyasa oynaklığını yansıtmadığını, aynı zamanda ileriye dönük beklenen getirilerle tutarlı bir risk fiyatlama içeriği taşıyabildiğini göstermesi bakımından önemlidir (Manela & Moreira, 2017).

Sosyal medya verileri de NLP tabanlı finansal tahmin literatüründe önemli bir yer tutmaktadır. Bollen, Mao ve Zeng (2011), Twitter üzerinden türetilen duygu göstergelerinin Dow Jones endeksinin yönünü tahmin etmede istatistiksel olarak anlamlı katkı sunduğunu göstermiştir. Çalışma, sosyal medya duyarlılığının geleneksel ekonomik göstergelerden daha hızlı tepki verebildiğini ve bu nedenle kısa vadeli tahminlerde avantaj sağlayabildiğini ortaya koymaktadır (Bollen ve diğerleri, 2011). Bununla birlikte sosyal medya kaynaklı metin sinyallerinin örneklem dönemine, platform dinamiklerine ve olası manipülasyonlara duyarlı olabileceği, bu nedenle out-of-sample protokollerin ve sağlamlık testlerinin kritik olduğuna dikkat edilmesi gereklidir.

Firma düzeyinde metin madenciliği uygulamaları, özellikle finansal raporlar üzerinden yoğunlaşmaktadır. Kogan ve diğerleri (2009), SEC-mandatlı yıllık finansal rapor metinlerinden (örn. 10-K) çıkarılan metinsel özelliklerle, şirket hisse senedi getirilerinin gelecekteki volatilitelerini (risk ölçütü) regresyon çerçevesinde tahmin etmiş ve metin tabanlı modelin tek başına geçmiş volatiliteler kadar güçlü bir baseline'a yaklaşabildiğini; metin ile geçmiş volatiliteler bilgisinin birlikte kullanıldığında ise tahmin performansının anlamlı biçimde iyileştiğini göstermiştir (Kogan ve diğerleri, 2009). Bu sonuç, nicel finans literatüründe metnin “yumuşak bilgi” olarak risk tahminine katkısının erken ve kurucu ampirik kanıtlarından biridir.

Türkiye'deki literatürde, doğrudan NLP tabanlı haber duyarlılığı ile getiri veya volatiliteler tahmini yapan geniş ölçekli ve yüksek atıflı ampirik çalışmalar görece sınırlıdır. Mevcut çalışmalar çoğunlukla betimleyici içerik analizine veya daha dar örneklemli uygulamalara yoğunlaşmaktadır. Bu durum, Türkiye bağlamında yapılacak yeni ampirik çalışmalar için (i) kapsamlı Türkçe haber arşivleri, (ii) alan-özgü sözlük uyarlamaları ve/veya transformer tabanlı modellerin Türkçe finans diline adaptasyonu, (iii) güçlü out-of-sample tasarımlar ve ekonomik anlamlılık testleri gibi boyutlarda belirgin bir araştırma alanı bulunduğu işaret etmektedir.

Genel olarak ampirik bulgular, NLP tabanlı metin değişkenlerinin finansal tahmin modellerinde tamamlayıcı bilgi kaynağı sunduğunu göstermektedir. Haber ve rapor metinlerinden türetilen duyarlılık ve belirsizlik göstergeleri, getirilerde kısa vadeli öngörü gücü sağlarken; volatiliteler ve risk ölçümlerinde daha kalıcı ve rejime duyarlı etkiler üretebilmektedir (Baker ve diğerleri, 2016; Manela & Moreira, 2017). Bununla birlikte, metin tabanlı sinyallerin veri

üretim sürecine, sözlük veya model seçimine ve dönemsel piyasa koşullarına duyarlı olduğu ampirik olarak da açıkça ortaya konmuştur. Bu nedenle, NLP yöntemlerinin finansal tahminde kullanımı, klasik sayısal modellerin yerine geçmekten ziyade, onları bilgi seti açısından zenginleştiren bir metodolojik genişleme olarak değerlendirilmelidir.

4. Portföy Optimizasyonu, Risk Paritesi ve Algoritmik Ticarete Makine Öğrenmesi Tabanlı Yaklaşımlar

Portföy optimizasyonu ve risk yönetimi literatüründe geleneksel Markowitz yaklaşımı, varlıklar arasındaki kovaryansları ve beklenen getirileri dikkate alarak minimum riskli veya en yüksek getiri sağlayan portföylerin belirlenmesini amaçlamaktadır. Bununla birlikte, bu yaklaşımın temel sınırlılıklarından biri, finansal piyasaların doğrusal olmayan yapısını ve zaman içinde değişen volatilité dinamiklerini yeterince yansıtamamasıdır. Bu sınırlılıkları aşmak amacıyla makine öğrenmesi (ML) algoritmaları, özellikle doğrusal olmayan ilişkilerin modellenmesinde ve yüksek boyutlu veri yapılarının işlenmesinde portföy optimizasyonu literatürüne yeni bir yöntemsel çerçeve kazandırmıştır. Bu bölümde, ML tabanlı yaklaşımların portföy optimizasyonu, risk paritesi ve algoritmik ticaret alanlarındaki uygulamaları, doğrulanabilir ampirik çalışmalar temelinde ele alınmaktadır.

Portföy optimizasyonunda ML kullanımına yönelik erken dönem ampirik katkılardan biri Brock, Lakonishok ve LeBaron (1992) tarafından sunulmuştur. Yazarlar, Dow Jones endeksi üzerinde hareketli ortalama ve “trading range break” kurallarının istatistiksel anlamlılığını bootstrap temelli testlerle sınamakta ve doğrusal olmayan örüntülerin (ör. trend-izleme sinyalleri) klasik rassal yürüyüş ve basit koşullu heteroskedastisite varsayımlarını zorlayacak ölçüde güçlü olabileceğini göstermektedir. Her ne kadar çalışma doğrudan bir portföy optimizasyon modeli önermese de, portföy/ticaret kararlarının “kural + veri” bileşimiyle, parametrik olmayan yöntemlerle değerlendirilebileceğini ampirik olarak ortaya koyması bakımından literatürde bir dönüm noktasıdır (Brock, Lakonishok ve LeBaron, 1992).

Makine öğrenmesi temelli yaklaşımların portföy yönetimine entegrasyonu, özellikle tahmin ile karar verme süreçlerinin bütünleştirilmesi bağlamında daha yakın dönem literatürde dikkat çekici biçimde artmıştır. Bu çerçevede Bertsimas ve Kallus (2020), makine öğrenmesi yöntemlerinin yalnızca varlık getirilerini tahmin etmek için değil, aynı zamanda bu tahminlerin doğrudan portföy tahsis kararlarına dönüştürüldüğü “öngöründen reçeteye (predictive-to-prescriptive analytics)” yaklaşımıyla kullanılabileceğini göstermiştir. Çalışma, (i) öngörü modellerinin doğrusal olmayan yapılarla zenginleştirilmesini, (ii) optimizasyon

amaç fonksiyonuna doğrudan gömülen karar kurallarıyla birleştirmekte; böylece geleneksel iki aşamalı (önce tahmin, sonra optimizasyon) çerçevelerin, tahmin hatasını portföy kararına mekanik biçimde taşıma riskini azaltmaya dönük bir tasarım sunmaktadır (Bertsimas ve Kallus, 2020). Bu yaklaşım, portföy inşasında ML'nin “saf tahmin doğruluğu” yerine, tahmin-hata duyarlılığı ve karar stabilitesi üzerinden değerlendirilmesi gerektiğini ampirik tasarım mantığıyla görünür kılar.

Makine öğrenmesi kökenli yöntemler, risk paritesi yaklaşımının sınırlılıklarını aşmaya yönelik yeni portföy inşa tekniklerinin geliştirilmesinde ampirik olarak kullanılmıştır. Bu bağlamda López de Prado (2016), klasik risk paritesinin kovaryans matrisinin tahminine aşırı duyarlılığını eleştirerek, hiyerarşik kümeleme temelli hiyerarşik risk paritesi (hierarchical risk parity, HRP) yaklaşımını önermiştir. HRP yöntemi, varlıklar arasındaki benzerlik yapısını hiyerarşik kümeleme ile açığa çıkarıp, ağırlıkları bu ağaç yapısı üzerinden tahsis ederek “kovaryans tahmin hatasına kırılabilirlik” sorununu pratikte azaltmayı hedefler. Ampirik bulgular, HRP portföylerinin örneklem dışı performansta daha istikrarlı getiriler sunabildiğini ve portföy yoğunlaşması (concentration) riskini sınırlayabildiğini göstermektedir (López de Prado, 2016).

Portföy optimizasyonuna ilişkin bu yönetsel kazanımlar, algoritmik ticaret literatürüne de yansımıştır. Zhang, Zohren ve Roberts (2020), derin güçlendirmeli öğrenme (deep reinforcement learning) algoritmalarını kullanarak portföy ağırlıklarının zaman içinde güncellendiği ve işlem maliyeti/sürtünme (friction) etkilerinin karar kuralına entegre edilebildiği bir öğrenme çerçevesi önermiştir. Ampirik analiz, modelin eğitim sürecinde risk-getiri hedefini ve kısıtları (örn. yeniden dengeleme maliyeti) birlikte öğrenebilmesinin, kural tabanlı stratejilere kıyasla bazı senaryolarda daha iyi uyum ve performans sağlayabildiğini göstermektedir (Zhang, Zohren ve Roberts, 2020). Bu çizgi, portföy seçiminin statik bir optimizasyon problemi olmaktan ziyade, “zaman içinde karar kuralı öğrenimi” olarak ele alınabileceğini vurgular.

Algoritmik ticarete ML kullanımının erken örneklerinden biri Hutchinson, Lo ve Poggio (1994) tarafından sunulmuştur. Yazarlar, türev ürünlerin fiyatlanması ve riskten korunma süreçlerinde öğrenen ağlar (learning networks) yaklaşımıyla doğrusal olmayan fiyatlama ilişkilerinin yakalanabileceğini ve hedge performansının veri-temelli biçimde iyileştirilebileceğini göstermiştir. Çalışma, finansal karar problemlerinde (fiyatlama/hedge) fonksiyon yaklaşımı perspektifini güçlendirerek, daha sonraki algoritmik ticaret ve otomatik portföy yönetimi literatüründe yaygınlaşacak öğrenen sistemlerin teorik-ampirik zeminini oluşturan erken bir referans niteliğindedir (Hutchinson, Lo ve Poggio, 1994).

Risk yönetimi literatüründe ML uygulamaları, özellikle piyasa riskinin nicel ölçümünde (VaR/ES) son yıllarda belirgin biçimde öne çıkmıştır. Chronopoulos, Raftapostolos ve Kapetanios (2024), derin sinir ağlarına dayalı kuantil tahmin ediciler (deep quantile estimator) ile Value-at-Risk (VaR) tahmini yaparak, doğrusal kuantil regresyon gibi klasik kıyas yöntemlerine göre örneklem-dışı tahminde anlamlı kazanımlar raporlamaktadır. Çalışma, (i) kuyruk riskinin doğrusal olmayan belirleyicilerini yakalama, (ii) yüksek boyutlu açıklayıcı setlerde düzenleştirmeye/ceza terimleriyle aşırı uyumu kontrol etme ve (iii) tahmin performansını kuantil-temelli doğrulama testleriyle değerlendirme bakımından, ML'nin risk ölçümüne “ampirik olarak ölçülebilir” bir katkı sunduğunu göstermektedir (Chronopoulos, Raftapostolos ve Kapetanios, 2024). Bu bakımdan VaR tahmini, ML'nin yalnızca getiriye değil, “dağılımın kuyruğunu” hedef alan finansal karar problemlerinin genişlediği bir uygulama alanı olarak okunmalıdır.

Makine öğrenmesi, algoritmik ticaret bağlamında piyasa anomalilerinin ve manipülatif davranışların tespitinde de kullanılmaktadır. Leangarun, Tangamchit ve Thajchayapong (2018), emir defteri (order book) verileri üzerinden normal piyasa davranışını denetimsiz biçimde öğrenen LSTM-GAN mimarisini kullanarak, “pump-and-dump” benzeri manipülatif örüntülerin tespitini ele almaktadır. Çalışma, manipülasyon vakalarının etiketli örneklerinin sınırlı olduğu pratik koşullarda, “normal veri ile öğren – anomaliyi ayıkla” yaklaşımının uygulanabilirliğini göstermesi bakımından önemlidir. Ayrıca, piyasadaki anomali tespiti probleminin yalnızca sınıflandırma değil, veri üretim sürecindeki dengesizlik (class imbalance) ve etiket kıtlığı koşullarında bir “gözetimsiz öğrenme + test” problemi olarak yeniden formüle edilebileceğini ampirik bir çerçevede tartışmaktadır (Leangarun, Tangamchit ve Thajchayapong, 2018).

Genel olarak değerlendirildiğinde, makine öğrenmesi tabanlı yaklaşımlar portföy optimizasyonu, risk paritesi ve algoritmik ticaret literatüründe veri işleme kapasitesini artırma, doğrusal olmayan piyasa davranışlarını modelleme ve risk-getiri dengesini iyileştirme potansiyeli taşımaktadır. Bununla birlikte ampirik literatürün ortak mesajı, performansın çoğu kez (i) örneklem dışı protokol tasarımına, (ii) işlem maliyeti ve kısıtların modele nasıl gömüldüğüne, (iii) tahmin hatasının karar kuralına aktarım mekanizmasına ve (iv) veri rejimi değişimlerine duyarlı olduğudur (Bertsimas & Kallus, 2020; López de Prado, 2016; Zhang ve diğerler, 2020). Bu nedenle yöntemsel sentez yapılırken, “hangi algoritma daha iyi?” sorusundan çok, “hangi problem tasarımında ML hangi kanaldan değer katıyor?” sorusu daha açıklayıcı bir çerçeve sunmaktadır.

5. Anomali Tespiti, Dolandırıcılık Analitiği ve Piyasa Mikro Yapısında ML Uygulamaları

Finansal piyasalarda “anomali” kavramı, iki farklı fakat birbirini tamamlayan düzlemde ele alınır. Birinci düzlem, finansal raporlama, işlem akışı veya müşteri davranışı gibi süreçlerdeki hileli/uyumsuz örüntülerin tespitiyle ilgilidir; burada amaç, kayıp azaltımı ve uyum (compliance) maliyetlerinin düşürülmesidir. İkinci düzlem ise piyasa mikro yapısında (özellikle limit emir defteri verisinde) olağandışı fiyat oluşumu, manipülatif düzenekler veya sıra dışı emir akışı gibi davranışların modellenmesi ve kısa ufukta (milisaniye–saniye–dakika) öngörü üretimidir. Bu iki düzlem, yöntemsel olarak büyük ölçüde ortak bir araç setini paylaşır: yüksek dengesiz sınıf yapısı (rare events), kavram kayması (concept drift), etiket gecikmesi, maliyet-asimetrik hata fonksiyonları ve açıklanabilirlik/denetlenebilirlik gereksinimi. Ampirik literatür, bu ortak kısıtları görünür kılan veri setleri ve değerlendirme protokolleri üzerinden ilerlemiş; dolandırıcılık ve anomali tespiti alanında ML'nin başarısı çoğu zaman yalnızca “doğruluk”la değil, alarm kapasitesi (precision/recall), yanlış alarm maliyeti ve operasyonel uygulanabilirlikle ölçülmüştür (Dal Pozzolo ve diğerleri, 2014; Dal Pozzolo ve diğerleri, 2015; Perols, 2011).

Finansal raporlama hilesi (financial statement fraud) literatüründe ML'nin ampirik katkısı, “klasik oran analizi + doğrusal sınıflandırıcı” yaklaşımının ötesine geçerek, doğrusal olmayan sınırlara ve etkileşimlere izin veren sınıflandırma modelleriyle şekillenmiştir. Cecchini, Aytug, Koehler ve Pathak (2010), halka açık şirketlere ilişkin temel finansal verilerle yönetim kaynaklı hileyi tespit etmeye yönelik bir destek vektör makineleri (SVM) çerçevesi kurmaktadır. Kritik katkı, finans alanına özgü bir çekirdek (kernel) tasarımıyla, hile sinyallerini güçlendiren doğrusal olmayan dönüşümlerin sınıflandırma performansını artırabileceğini ampirik olarak göstermesidir (Cecchini ve diğerleri, 2010). Bu sonuç, hile tespitinde “model karmaşıklığı” kadar “özellik uzayının finansal anlamlılığı”nın da belirleyici olabileceğine işaret etmektedir. Başka bir ifadeyle, ML'nin başarısı salt algoritma seçimine indirgenemez, finansal temsilin kalitesi belirleyicidir (Cecchini ve diğerleri, 2010).

Bu çizgiyi daha sistematik bir karşılaştırma tasarımına taşıyan Perols (2011), finansal tablo hilesi tespitinde lojistik regresyon, SVM, yapay sinir ağları, torbalama (bagging), C4.5 karar ağacı ve yığınlama (stacking) gibi birden çok yöntemi farklı maliyet yapıları ve sınıf oranları altında test etmektedir. Ampirik bulguların önemli kısmı “pratik uyarı” niteliğindedir: Her koşulda en karmaşık modelin üstün gelmediği; bazı kurulumlarda lojistik regresyon ve SVM gibi yöntemlerin, daha karmaşık topluluk veya sinir ağı yaklaşımlarına karşı rekabetçi olabildiği gösterilmektedir (Perols, 2011). Bu sonuç, hile

tespiti probleminde veri yapısının (özellikle dengesizlik ve etiket kalitesi) algoritma seçimini domine edebileceğini işaret etmektedir. Ayrıca performansın AUC gibi genel ölçütlerden ziyade operasyonel hedefe uygun maliyet-duyarlı ölçütlerle değerlendirilmesi gerektiğini vurgulamaktadır (Perols, 2011). Dolayısıyla ampirik literatür, finansal raporlama hilesinde ML kullanımının, denetim süreçlerine entegre edilecek şekilde yanlış alarm oranı, yakalama oranı ve inceleme kapasitesi gibi kısıtlar altında raporlanmasını metodolojik bir zorunluluk olarak konumlandırmıştır.

Dolandırıcılık analitiğinin en yoğun uygulama alanlarından biri ödeme sistemleri ve kredi kartı işlemleridir. Burada temel zorluk, etiketlerin nadirliği (dolandırıcılık oranlarının çok düşük olması), davranışların zamana göre değişmesi ve çoğu zaman etiketlerin gecikmeli gelmesidir. Dal Pozzolo ve diğerleri (2014), gerçek bir endüstriyel veri seti üzerinde farklı algoritmaları ve modelleme stratejilerini deneysel olarak kıyaslamaktadır. Çalışmanın merkezinde üç problem vardır: dengesiz sınıflar, durağan olmama (non-stationarity) ve değerlendirme. Ampirik bulgular, “tek seferlik eğitim” ile “sürekli güncelleme” arasında anlamlı performans farkları olabileceğini; örnekleme (undersampling/oversampling) stratejilerinin ve unutma (forgetting) mekanizmalarının pratikte kritik rol oynadığını göstermektedir (Dal Pozzolo ve diğerleri, 2014). Bu sonuçlar, dolandırıcılık tespitinde MLnin yalnızca bir sınıflandırıcı seçmekten ibaret olmadığını, veri akışına uyum sağlayan bir öğrenme sistemi tasarımı gerektirdiğini desteklemektedir.

Aynı araştırma hattında Dal Pozzolo ve diğerleri (2015), etiketlerin gecikmeli geldiği bir ortamda kavram kayması uyarlamasını (concept-drift adaptation) ele almaktadır. Ayrıca akış verisi (datastream) bağlamında dolandırıcılık tespitinin tasarım sorunlarını ampirik olarak ortaya koymaktadır. Çalışma, gecikmeli gözetimli bilginin (delayed supervised information) pratikte kaçınılmaz olduğunu; bu nedenle model güncellemelerinin, “tam ve anlık etiket varsayımı” yerine gerçekçi iş akışına göre kurulması gerektiğini göstermektedir (Dal Pozzolo ve diğerleri, 2015). Bu yaklaşım, değerlendirme protokollerini de doğrudan etkilemektedir. Rastgele ve zaman sırasını bozan eğitim-test ayrımları yerine, verinin gerçek zaman akışını izleyen zaman temelli ayrımların ve gecikmeli geri besleme mekanizmalarının kullanılması, model performansının gerçekte olduğundan daha yüksek görünmesine yol açan yanlışlıkları azaltmaktadır.

Piyasa mikro yapısı boyutunda ise ML uygulamaları, anomali tespitinden “yüksek frekansta fiyat oluşumu”nun modellenmesine doğru genişletmektedir. Emir defteri (LOB) verileri yüksek boyutlu, gürültülü ve yoğun etkileşimli yapısıyla, geleneksel zaman serisi modelleri için zorlayıcıdır. Kercheval ve

Zhang (2015), LOB dinamiklerini çok-sınıflı SVM çerçevesinde modelleyerek orta fiyatın (mid-price) kısa vadeli yönünü ve spread crossing gibi metrikleri tahmin etmeye dönük bir yapı kurmaktadır. Çalışma, LOB gibi mikro yapısal veri üzerinde “özellik çıkarımı + sınıflandırma” yaklaşımının erken ve etkili ampirik örneklerinden biridir (Kercheval & Zhang, 2015). Burada MLnin rolü, emir defterinin çok katmanlı yapısını (farklı fiyat seviyeleri ve derinlik) özetleyen özellikler üzerinden kısa vadeli fiyat hareketini istatistiksel olarak yakalamaktır.

Derin öğrenme yaklaşımları mikro yapı literatürünü belirgin biçimde dönüştürmüştür. Sirignano (2016), limit emir defterindeki farklı fiyat seviyelerini açık biçimde modele dahil eden bir sinir ağı yapısı kullanarak, emir defterinin yalnızca en iyi alış-satış seviyelerinin değil, daha derin katmanlarının da kısa vadeli fiyat hareketleri hakkında ilave ve anlamlı bilgi içerdiğini göstermektedir. Bu hat, daha sonra DeepLOB mimarisiyle kurumsallaşmaktadır. Zhang, Zohren ve Roberts (2019), LOB verisinin mekânsal örüntülerini evrimsel katmanlarla, zamansal bağımlılığını ise LSTM modülleriyle yakalayan bir model önermektedir. Modelin performansı, hem standartlaştırılmış LOB karşılaştırma veri setinde hem de gerçek piyasa kotasyonları üzerinde yapılan örneklem dışı testlerde değerlendirilmiştir. Sonuçlar, önerilen yaklaşımın mevcut yöntemlere kıyasla daha yüksek ve daha istikrarlı bir tahmin başarısı sağladığını göstermiştir (Zhang ve diğerleri, 2019). DeepLOB çizgisinin mikro yapı literatürüne katkısı, LOB verisinde “temsili öğrenmesi”nin elle tasarlanmış özellik setlerine göre güçlü bir alternatif sunmasıdır. Bu durum, anomali tespitine de metodolojik bir köprü kurmaktadır çünkü olağandışı örüntüler çoğu zaman öğrenilen temsili uzayında daha belirgin ayrılmaktadır.

Mikro yapıda MLnin “genellenebilirlik” iddiasını gündeme taşıyan ampirik çalışmalardan biri Sirignano ve Cont (2019)’dur. Yazarlar, ABD hisse senetlerine ait çok büyük ölçekli yüksek frekanslı veriyi analiz etmektedir. Derin öğrenme yaklaşımıyla arz ve talep dinamikleri ile fiyat değişimleri arasındaki ilişkinin evrensel ve durağan bir yapı sergileyebildiğini göstermektedir. Ayrıca, tekil varlıklara özgü modeller yerine çoklu varlık havuzundan öğrenen modellerin daha istikrarlı örneklem dışı doğruluk sağladığını ifade etmektedir (Sirignano & Cont, 2019). Bu bulgu, (i) LOB tahmininde örneklem büyüklüğünün ve çapraz-varlık havuzlamanın kritik olduğu; (ii) bazı “anomali benzeri” davranışların (örn. olağandışı emir akışı örnekleri) varlıklar arasında ortak yapılara sahip olabileceği fikrini güçlendirmektedir.

Algoritmik ticaret ve piyasa mikro yapısı uygulamalarında “anomali” kavramı çoğu zaman doğrudan dolandırıcılık anlamına gelmemektedir. Bu kavram, olağan piyasa koşullarından sapmaları içermektedir. Bu sapmalar

arasında likidite şokları yer almaktadır. Sıra dışı emir iptalleri de bu kapsamda değerlendirilmektedir. Ayrıca yürütme maliyetlerinde ani artışlar gözlemlenebilmektedir.

Bu tür durumlarda makine öğrenmesi tabanlı karar sistemleri yalnızca tahmin üretmemektedir. Bu sistemler aynı zamanda işlem yürütme problemine de uzanmaktadır. Nevmyvaka, Feng ve Kearns (2006), optimize edilmiş işlem yürütme problemini ele almaktadır. Çalışma, pekiştirmeli öğrenme yaklaşımını büyük ölçekli limit emir verisi üzerinde ampirik olarak uygulamaktadır. Elde edilen bulgular, yürütme maliyetlerini azaltmaya yönelik politika öğreniminin mümkün olduğunu göstermektedir (Nevmyvaka ve diğerleri, 2006).

Bu çalışma, piyasa mikro yapısında makine öğrenmesinin tahminden karara uzanan sürece entegre edildiği erken ampirik örnekler arasında yer almaktadır. Anomali tespiti açısından bakıldığında, yürütme maliyetlerindeki sapmalar önem taşımaktadır. Piyasa koşullarındaki ani rejim değişimleri de kritik rol oynamaktadır. Bu unsurlar, öğrenilen politikaların performansını doğrudan etkilemektedir.

Ampirik literatürde ortak bir metodolojik sonuç daha belirgin hâle gelmektedir. Anomali tespiti ve dolandırıcılık analitiğinde performansın sürdürülebilirliği, veri üretim sürecindeki değişimlere ve denetim ile operasyon kısıtlarına bağlıdır. Ödeme dolandırıcılığı alanında bu tür değişimler açık biçimde gözlenmektedir (Dal Pozzolo ve diğerleri, 2014; Dal Pozzolo ve diğerleri, 2015).

Piyasa mikro yapısında ise bu değişimler farklı nedenlerle ortaya çıkmaktadır. Piyasa rejimlerindeki dönüşümler bu nedenler arasında yer almaktadır. Asgari fiyat adımı değişiklikleri ve katılımcı yapısındaki farklılaşmalar da süreci etkilemektedir. Algoritmik rekabetin yoğunlaşması da önemli bir faktör oluşturmaktadır. Bu unsurlar, durağan varsayımlara dayalı öğrenme yaklaşımlarının performansını zaman içinde zayıflatmaktadır (Sirignano & Cont, 2019; Zhang ve diğerleri, 2019).

Finansal raporlama hilesi bağlamında benzer bir durum söz konusudur. Burada değişim, düzenleyici çerçevedeki güncellemelerle ilişkilidir. Raporlama standartlarının evrimi ve denetim teknolojilerindeki ilerlemeler de bu süreci şekillendirmektedir. Bu nedenle bir modelin geçmiş döneme ait performansı, gelecekteki operasyonel başarısını garanti etmemektedir (Perols, 2011; Cecchini ve diğerleri, 2010).

Bu üç alanın kesişiminde ortak bir tasarım ilkesi ortaya çıkmaktadır. Finansal anomali tespitinde makine öğrenmesi, yalnızca yüksek doğruluk sağlayan bir algoritma seçimi değildir. Aynı zamanda veri akışına uyum sağlamaktadır.

Maliyet duyarlılığını gözetmektedir. Denetlenebilirlik gereksinimlerini de karşılamaktadır. Dolayısıyla bu alan, bütüncül bir sistem mühendisliği problemi olarak ele alınmaktadır (Dal Pozzolo ve diğerleri, 2014; Perols, 2011).

6. Sonuç

Bu çalışmada, makine öğrenmesi yöntemlerinin finansal akademik literatüründe yöntemsel bir araç olarak nasıl kullanıldığı ve farklı finansal problem alanlarında ne tür katkılar sunduğunu dört ana boyut çerçevesinde değerlendirilmiştir. İncelenen ampirik bulgular, makine öğrenmesi algoritmalarının özellikle doğrusal olmayan ilişkilerin baskın olduğu ve yüksek boyutlu veri yapılarına sahip finansal problemlerde önemli avantajlar sağladığını göstermektedir. Getiri, volatilité ve risk öngörüsü alanında bu yöntemlerin, belirli koşullar altında klasik doğrusal modellere kıyasla daha yüksek örneklem dışı performans ve ekonomik anlamlılık üretebildiği görülmektedir.

Doğal dil işleme ve metin madenciliği uygulamaları, finansal haberler ve raporlar gibi yapılandırılmamış veri kaynaklarının analize dâhil edilmesiyle, piyasa beklentileri ve belirsizlik algısının daha kapsamlı biçimde ölçülmesine olanak tanımaktadır. Bu durum, finansal tahmin modellerinin bilgi setini genişleterek geleneksel nicel göstergeleri tamamlayıcı bir rol üstlenmektedir. Portföy optimizasyonu ve algoritmik ticaret bağlamında ise makine öğrenmesi, tahmin ve karar süreçlerini bütünléstiren dinamik yapılar sunmakta; işlem maliyetleri, yeniden dengeleme kısıtları ve zaman içinde öğrenen stratejiler ön plana çıkmaktadır.

Anomali tespiti, dolandırıcılık analitiği ve piyasa mikro yapısı alanlarında elde edilen sonuçlar, makine öğrenmesinin yalnızca tahmin doğruluğu açısından değil, aynı zamanda operasyonel etkinlik, maliyet duyarlılığı ve piyasa bütünlüğü açısından da kritik bir araç olduğunu ortaya koymaktadır. Bununla birlikte literatür, bu yöntemlerin başarısının veri kalitesi, değerlendirme protokolleri ve piyasa rejimlerindeki değişimlere uyum kapasitesine güçlü biçimde bağlı olduğunu göstermektedir. Sonuç olarak, makine öğrenmesi finans alanında evrensel bir çözüm olarak değil; problem bağlamına duyarlı, dikkatli biçimde tasarlanmış ve klasik yöntemlerle tamamlayıcı şekilde kullanılan bir yöntemsel çerçeve olarak değerlendirilmelidir.

Kaynakça

- Baker, S. R., Bloom, N., & Davis, S. J. (2016). Measuring economic policy uncertainty. *The Quarterly Journal of Economics*, 131(4), 1593–1636.
- Bertsimas, D., & Kallus, N. (2020). From predictive to prescriptive analytics. *Management Science*, 66(3), 1025–1044.
- Bollen, J., Mao, H., & Zeng, X. (2011). Twitter mood predicts the stock market. *Journal of Computational Science*, 2(1), 1–8.
- Brock, W., Lakonishok, J., & LeBaron, B. (1992). Simple technical trading rules and the stochastic properties of stock returns. *The Journal of Finance*, 47(5), 1731–1764.
- Cecchini, M., Aytug, H., Koehler, G. J., & Pathak, P. (2010). Detecting management fraud in public companies. *Management Science*, 56(7), 1146–1160.
- Chronopoulos, I., Raftapostolos, A., & Kapetanios, G. (2024). Forecasting Value-at-Risk using deep neural network quantile regression. *Journal of Financial Econometrics*, 22(3), 636–669.
- Dal Pozzolo, A., Boracchi, G., Caelen, O., Alippi, C., & Bontempi, G. (2015). Credit card fraud detection and concept-drift adaptation with delayed supervised information. In *2015 International Joint Conference on Neural Networks (IJCNN)*. IEEE.
- Dal Pozzolo, A., Caelen, O., Le Borgne, Y.-A., Waterschoot, S., & Bontempi, G. (2014). Learned lessons in credit card fraud detection from a practitioner perspective. *Expert Systems with Applications*, 41(10), 4915–4928.
- Engelberg, J. E., & Parsons, C. A. (2011). The causal impact of media in financial markets. *The Journal of Finance*, 66(1), 67–97. Fang, L., & Peress, J. (2009). Media coverage and the cross-section of stock returns. *The Journal of Finance*, 64(5), 2023–2052. Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669.
- Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. *The Review of Financial Studies*, 33(5), 2223–2273.
- Hutchinson, J. M., Lo, A. W., & Poggio, T. (1994). A nonparametric approach to pricing and hedging derivative securities via learning networks. *The Journal of Finance*, 49(3), 851–889.
- Kara, Y., Boyacıoğlu, M. A., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*, 38(5), 5311–5319.
- Kercheval, A. N., & Zhang, Y. (2015). Modelling high-frequency limit order book dynamics with support vector machines. *Quantitative Finance*, 15(8), 1315–1329.

- Kim, H. Y., & Won, C. H. (2018). Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models. *Expert Systems with Applications*, 103, 25–37.
- Kogan, S., Levin, D., Routledge, B. R., Sagi, J. S., & Smith, N. A. (2009). Predicting risk from financial reports with regression. *Proceedings of Human Language Technologies: The 2009 Annual Conference of the North American Chapter of the Association for Computational Linguistics*, 272–280.
- Krauss, C., Do, X. A., & Huck, N. (2017). Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *European Journal of Operational Research*, 259(2), 689–702.
- Leangarun, T., Tangamchit, P., & Thajchayapong, S. (2018). Stock price manipulation detection using generative adversarial networks. In *2018 IEEE symposium series on computational intelligence (SSCI)* (pp. 2104–2111). IEEE.
- López de Prado, M. (2016). Building diversified portfolios that outperform out of sample. *The Journal of Portfolio Management*, 42(4), 59–69.
- Loughran, T., & McDonald, B. (2011). When is a liability not a liability? Textual analysis, dictionaries, and 10-Ks. *The Journal of Finance*, 66(1), 35–65.
- Manela, A., & Moreira, A. (2017). News implied volatility and disaster concerns. *Journal of Financial Economics*, 123(1), 137–162.
- Nevmyvaka, Y., Feng, Y., & Kearns, M. (2006). Reinforcement learning for optimized trade execution. In *Proceedings of the 23rd International Conference on Machine Learning (ICML)*.
- Patton, A. J., & Sheppard, K. (2015). Good volatility, bad volatility: Signed jumps and the persistence of volatility. *The Review of Economics and Statistics*, 97(3), 683–697.
- Perols, J. (2011). Financial statement fraud detection: An analysis of statistical and machine learning algorithms. *Auditing: A Journal of Practice & Theory*, 30(2), 19–50.
- Rapach, D. E., Strauss, J. K., & Zhou, G. (2010). Combination forecasts and links to the real economy. *The Review of Financial Studies*, 23(2), 821–862.
- Rapach, D. E., Strauss, J. K., & Zhou, G. (2013). International stock return predictability: What is the role of the United States? *The Journal of Finance*, 68(4), 1633–1662.
- Sirignano, J. (2016). Deep learning for limit order books. *arXiv* (1601.01987).
- Sirignano, J., & Cont, R. (2019). Universal features of price formation in financial markets: Perspectives from deep learning. *Quantitative Finance*, 19(9), 1449–1459.
- Şahin, C. (2023). Garch ve yapay sinir ağları modelleri yardımıyla volatilité tahmini: Türk borsası örneği. *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 25(2), 572–595.

- Tetlock, P. C. (2007). Giving content to investor sentiment: The role of media in the stock market. *The Journal of Finance*, 62(3), 1139–1168.
- Tetlock, P. C., Saar-Tsechansky, M., & Macskassy, S. (2008). More than words: Quantifying language to measure firms' fundamentals. *The Journal of Finance*, 63(3), 1437–1467.
- Yiğit, Ö. E., & Karaköse, M. (2021). Teknik göstergeleri makine öğrenimi modellerine entegre ederek şehir endeksi hareketinin yönünü tahmin etmeye yönelik bir yaklaşım. *Hitit Sosyal Bilimler Dergisi*, 14(2), 556–575.
- Zhang, Z., Zohren, S., & Roberts, S. (2019). DeepLOB: Deep convolutional neural networks for limit order books. *IEEE Transactions on Signal Processing*, 67(11), 3001–3012.
- Zhang, Z., Zohren, S., & Roberts, S. (2020). Deep learning for portfolio optimization. *arXiv preprint arXiv:2005.13665*.