



İLK HALKA ARZLARDA UZUN DÖNEM GETİRİLERİNİN TAHMİNİ: YAPAY SİNİR AĞLARI İLE İMKB İÇİN AMPİRİK BİR ÇALIŞMA

Öğr. Gör. Ulaş ÜNLÜ *

Yrd.Doç.Dr. Birol YILDIZ **

Yrd.Doç. Dr. Abdullah YALAMA ***

Abstract

The purpose of this study is to estimate the long run IPO (Initial Public Offerings) returns using artificial neural network (ANN) and linear regression (LR). In wide-ranging literature linear regression is commonly preferred to estimate long run IPO returns. This study applies ANN addition to LR. As a result of comparing the performance of ANN and LR, ANN has better performance than OLS for long run IPO returns in Turkey.

Keywords: Initial public offerings, long-run performance, ANN, OLS, ISE.

Jel Classification: C520, G140, G390

Özet

Bu çalışmanın amacı İMKB’de ilk defa halka arz edilen hisse senetlerinin uzun dönem getirilerini yapay sinir ağı kullanarak tahmin etmektir. Literatürde uzun dönem halka arz getirilerinin tahmin edilmesinde yaygın olarak Doğrusal regresyon yönteminden yararlanıldığı görülmektedir. Bu çalışmada ise doğrusal regresyon yöntemine ek olarak yapay sinir ağı teknolojisi kullanılmıştır. Uzun dönem getirileri tahmin etmede doğrusal regresyon ve yapay sinir ağı modellerinin performansları karşılaştırılmıştır. Elde edilen bulgular yapay sinir ağının uzun dönem halka arz getirilerini tahmin etmede doğrusal regresyon yönteminden daha başarılı olduğunu ortaya koymaktadır.

Anahtar Kelimeler: Halka arz, uzun dönem performans, yapay sinir ağı, doğrusal regresyon, İMKB.

Jel Sınıflaması : C520, G140, G390

* **Adres:** Nevşehir Üniversitesi MYO

E-Mail: ulasunlu@gmail.com

** **Adres:** Eskişehir Osmangazi Üniversitesi, İşletme Bölümü

E-Mail: birol.yildiz@gmail.com

*** **Adres:** Eskişehir Osmangazi Üniversitesi, İşletme Bölümü

E-Mail: abduallah.yalama@gmail.com



1.Giriş

Firmaların en önemli sermaye kaynaklarından birisini halka arzlar oluşturmaktadır. Halka arzların yatırımcılar için önemi daha çok ilk halka arz edilen hisse senetlerinden ne kadar sermaye kazancı sağlayabilecekleri ile ilgili olmaktadır. Dolayısıyla halka arzların kısa veya uzun dönemde sağlayacağı getiriye doğru öngörmek yatırımcılar için önemli fırsatlar doğurabilecektir. Yatırımcı açısından bu öngörü temel bir problemdir. Bu problemin çözümünde kullanılacak alternatif bir yöntemin tahmin performansındaki sağlayacağı artış, yatırımcılar açısından oldukça büyük fırsatlara dönüştürülebilecektir.

İlk halka arzlar uzun süreden beri araştırmacıların finans literatüründe ilgiyle üzerinde durduğu konulardan biri halini almıştır. Bu alanda yapılan çalışmalar genel olarak kısa *dönem düşük fiyatlama* ve *uzun dönem düşük performans* olmak üzere iki anomali üzerine yoğunlaşmıştır.

Hisse senetlerinin ilk işlem gününde piyasanın üzerinde bir getiri elde ederek gerçek değerinin altında fiyatlanmasına “*düşük fiyatlama*” adı verilmektedir. Kısa dönemli bu olgunun geçerliliğine yönelik birçok ampirik bulgu hem gelişmiş hem de gelişmekte olan ülkeler adına literatürde yerini almıştır (ABD: Tınıç, 1988; Levis, 1993, Ritter ve Welch, 2002; İngiltere: Levis, 1993, Ljungqvist, 2003, İsviçre: Kunz ve Aggarwal, 1994; İspanya: Ansotegui vd. 2000; Brezilya: Aggarwal vd. 1993, Singapur: Lee vd, 1996, Nijerya: Ikoku, 1996, Meksika: Aggarwal, Leal ve Hernandez, 1993, Türkiye: Kıymaz, 2000, Durukan, 2002, Ünlü ve Ersoy, 2008).

Düşük fiyatlamamanın nedeni ise daha çok varlıkların büyüklüğü, aracı kurumun prestiji, firmanın faaliyet süresi, satışlar, teknoloji firmaları, 1999 ve 2000 yılı ihraçları(IPO bubble) olgusuna dayandırılmaktadır(Ritter, 2003; Ljungqvist ve Wilhelm Jr., 2003; Ritter, 2005; Loughran ve Ritter, 2004).

İlk defa halka arzların uzun dönemde düşük performans gösterdiklerine dair öncü çalışma Ritter (1991) tarafından gerçekleştirilmiş, daha sonra ise gelişmiş ve gelişmekte olan birçok ülke için bu hipotezi destekleyen bulgulara rastlanmıştır (ABD: Loughran ve Ritter 1994; Brezilya: Aggarwal vd.1993; İsveç: Loughran vd.1994, İngiltere: Levis, 1993, Avustralya: Lee vd. 1996; Yeni Zelanda: Firth, 1997; Kanada: Jog, 1997; Almanya: Ljungqvist, 1997; Japonya: Cai ve Wei, 1997; Uluslararası pek çok piyasa için: Jenkinson ve Ljungqvist, 2001; Türkiye: Özer, 1999; Yalama ve Ünlü, 2010).



Bununla birlikte bazı arařtırmacılar, halka arzlarda *uzun dönemde düşük performans* hipotezini reddeden ampirik bulgular sunmuşlardır (Boardman ve Laurin 2000; Dewenter ve Malatesta, 2001, Kim vd. 1995; Kıymaz 1997a; Kıymaz 1997b).

Literatürde ilk defa halka arz edilen hisselerin uzun dönemli getirilerini tahmin etmek için yapılan çalışmalarda daha çok doğrusal regresyon yönteminin kullanıldığı görülmektedir. Bu tahminci değişkenler arasındaki doğrusal ilişkiyi, dayandığı birçok varsayımın geçerliliği halinde açıklamaktadır. Bu kapsamda alternatif metotlar sürekli arařtırmacıların ilgisini çekmiştir. Bunlardan birisi olan yapay sinir ağı teknolojisi, bağımlı ve bağımsız değişkenler arasındaki doğrusal olmayan ilişkileri modelleyebilmesi ve belirli varsayımlara dayanmaması sebebiyle geleneksel yöntemlerden ayrılır. Bu sebepler yapay sinir ağı metodunu, ilk halka arzı gerçekleştirilen hisse senetlerinin uzun dönemli performansını tahmin etmek için alternatif bir araç konumuna getirmektedir.

Bu çalışmada İMKB’de ilk halka arz edilen hisse senetlerinin uzun dönem getirilerini tahmin etmek için yapay sinir ağı modeli geliştirilmiştir. Geliştirilen modelin tahmin performansı doğrusal regresyon ile geliştirilen modelin tahmin performansı ile karşılaştırılmıştır.

Türkiye’de ilk defa halka arz edilen hisse senetleriyle ilgili literatür incelendiğinde yapılan çalışmaların uluslararası literatürdeki yayılımla paralel olarak daha çok düşük fiyatlama ve kısa dönem performans üzerinde yoğunlaştığı görülmektedir. Uzun dönem performans arařtıran çalışma sayısı ise kısıtlı olmakla birlikte bu çalışmalarda genel kabul görmüş bir yargıya ulaşılamamıştır. Bu çalışmanın literatürdeki diğer çalışmalardan farkı uzun dönem performansı ölçmede doğrusal regresyona alternatif olarak yapay sinir ağı modelinin performansını test etmesidir. Ayrıca bu çalışma Türkiye’de uzun dönem halka arz getirilerinin tahmininde yapay sinir ağlarını kullanan ilk çalışma olması açısından literatürdeki diğer çalışmalardan ayrılmaktadır.

Bu çalışmada izleyen bölümlerinde halka arz edilen hisse senetlerinin uzun dönemli performansını tahmin etme konusundaki literatür, veri, yöntem, ampirik bulgular ve sonuç incelenmiştir.

2.Literatür

Uzun dönemli halka arz literatüründe getirinin hesaplanması ve dönemin seçilmesi konusunda birçok farklı yaklaşım benimsenmiştir. İlk halka arzların uzun dönem



performanslarını inceleyen araştırmacılar araştırma periyodu olarak genellikle 36 ay (Ritter, 1991, Kıymaz, 1997) kullanmakla birlikte 60 aylık (Rajan ve Servaes, 1997; Eckbo ve Norli, 2005, Barber ve Lyon, 1997) inceleme dönemi belirleyen çalışmalar da mevcuttur. Uzun dönem getiri hesaplanırken ise çoğunlukla CAR(Ritter, 1991; Kıymaz, 1997a,b; Aggarwal ve Rivoli, 1990; Carter vd. 1998) ve MBHR (Eckbo ve Norli, 2005) olmak üzere iki farklı getiri hesaplama yöntemi kullanılmaktadır. Bunlardan ilki CAR (cumulatif abnormal return) piyasaya göre düzeltilmiş kümülatif anormal getiri diğeri ise MBHR (Market Adjust Buy and Hold Return) piyasaya göre düzeltilmiş satın al ve elde tut getirileridir.

İlk halka arzların uzun dönem performanslarına ilişkin ilk önemli çalışma Ritter (1991)'in çalışmasıdır. Ritter ABD'de 1975–1984 döneminde 1526 ilk halka arz işleminde ilk gün getirileri pozitif bulurken, 36 aylık süre sonunda kümülatif ortalama anormal getirileri %-29,1 olarak tespit etmiştir. Bu çalışmayla birlikte pek çok piyasada ilk halka arzların uzun dönem performansları ilgiliyle takip edilen bir konu olmuştur.

Uzun dönem performansa etki eden faktörler için farklı bulgular bulunmaktadır. Carter vd. (1998) ve Ritter'e (1991) göre genç firmalar uzun dönemde diğer firmalara göre daha düşük performans göstermektedirler. Uzun dönemde elde edilen performansı düşük fiyatlama modelleriyle açıklayan ve ilk gün getirilere bağlayan çalışmalar bulunmaktadır(Weiss, 1993; Alexander, 1993). Bazı araştırmacılar da sahiplik yapısının ve bununla bağlantılı olarak temsilci maliyetinin uzun dönem performansı etkilediğini savunmaktadır (Jain ve Kini, 1994; Mikkelson vd. 1997). Uzun dönemde düşük performans elde edilmesinin nedeninin bazı çalışmalarda yanlış ölçüm yapılması ve yanlış benchmark seçimi olabileceği iddia edilmektedir (Brav, Geczy, ve Gompers, 2000; Barber ve Lyon, 1997; Kothari ve Warner, 1997). Bu problemi ortadan kaldırmak için çok faktörlü varlık fiyatlama modelleri kullanılmaktadır (Loughran ve Ritter, 2000; Brav ve Gompers 1997; Eckbo ve Norli, 2005). Loughran ve Ritter (2000) uzun dönemde düşük performans tespit ederken, Brav ve Gompers (1997) ile Eckbo ve Norli (2005) ise ilk halka arzların uzun dönemde düşük performans göstermediğini göstermişlerdir. Heaton (2002), Daniel, Hirshleifer ve Subrahmanyam (1998) ile Bernardo ve Welch (2001) uzun dönemde elde edilen düşük performansın nedeni olarak, yönetici ve yatırımcıların kendine güvenmelerini göstermişlerdir. Carter, Dark, ve Singh (1998) ise uzun dönem performansı için en önemli belirleyici faktörün aracı kurumun prestiji olduğunu tespit etmiştir. Eckbo ve Norli (2005), Fama-French'in(1993,1996) üç faktör modelini ve Carhart'ın(1997) dört faktör modelini kullanarak, beş faktörlü bir varlık fiyatlama



modeli geliştirmiştir. Modelde kullanılan likidite faktörünün, ilk halka arzların uzun dönem performanslarını açıklamada önemli bir rol oynadığı tespit edilmiştir.

Türkiye’de ise ilk halka arzların uzun dönem performansını belirlemek için az sayıda çalışma yapılmış olup birbirinden farklı sonuçlara ulaşılmıştır. Kıymaz (1997a) çalışmasında 1990–1995 döneminde halka arz edilen sınaî sektör hisse senetlerinin uzun dönem performanslarını araştırmıştır. Araştırma sonucuna göre sınaî sektör hisse senetleri uzun dönemde ortalama %41,33’lük piyasa getirisine göre düzeltilmiş getiri elde etmişlerdir. Kıymaz(1997b) bir başka çalışmasında ise 1990–1995 döneminde halka arz edilen mali sektör hisse senetlerinin uzun dönem performanslarını araştırmış ve sonuç olarak mali sektör hisse senetlerinin 30 ayda %11’lik bir anormal getiri elde ettiğini göstermektedir. Belirsizliği fazla olan firmalar uzun dönemde daha iyi performans göstermiş ayrıca ilk gün düşük fiyatlanan hisse senetleri uzun dönemde daha az getiri elde etmişlerdir. Özer (1999) çalışmasında, 1989 – 1994 döneminde ilk defa halka arz edilen 89 hisse senedinin performansını araştırmıştır. Bu çalışmanın uzun dönem sonuçlarına göre, ilk halka arz edilen hisse senedi getirileri, ilk halka arz sonrası 500 gün içinde önce azalan, daha sonra artan bir trend izlemektedir. Fakat 500 gün sonunda elde edilen getiri ikinci hafta sonunda elde edilen getirinin altında kaldığını tespit etmiştir. Bu performansı etkileyen değişkenler ise aracı kurum ve şirket arasındaki ilişki ile halka açılma anındaki piyasa trendidir. Ayden ve Karan (2000) 1992–1995 yılları arasında halka arz edilen 70 firmanın 36 ay sonraki performanslarını incelemiştir. Elde edilen sonuçlara göre sadece 11. ayda istatistiksel olarak anlamlı ucuz hisse senedi varlığı tespit edilmiş olup, kümülâtif anormal getiriler anlamsız bulunmuştur. Çalışmada kullanılan diğer bir yöntemde göreceli refah göstergesidir. Bu yöntemde göre de uzun dönemde pahalı hisse senedi olgusuna rastlanmıştır. Ayrıca uzun dönemde normalin üstünde bir getiri elde etme yönünde oluşturulacak yatırım stratejilerinin anlamlı olmadığı savunulmaktadır. Durukan(2002), çalışmasında 1990–1997 yılları arasında ilk halka arz edilen 173 hisse senetlik bir örneklem kullanarak getirileri 36 aya kadar incelemiştir. Araştırma sonuçları “fads ve Winner’s Curse” hipotezlerini desteklerken, uzun dönemde düşük performans için herhangi bir kanıt sağlamamaktadır. Kıymaz(1997a,b) ve Özer’in(1999) aksine ilk gün getiriler ve uzun dönem getiriler arasında negatif ilişki bulunmuş ve özelleştirilen firmalar ise uzun dönemde daha iyi performans göstermişlerdir. Yalama ve Ünlü(2010) ise ilk halka arzların kısa ve uzun dönem performansları üzerinde takvim anomalileri etkisini inceleyerek İMKB için bu konuya farklı bir bakış açısı getirmiştir. Sonuç olarak çalışma kısa dönemde



İlk Halka Arz. Uzun Dön. Get. Tahmini: Yapay Sinir Ağları ile İMKB için Amp. Bir Çalışma

düşük fiyatlama ve uzun dönemde düşük performans olgusunu desteklemektedir. Ayrıca Türkiye’de 1990-2005 döneminde gerçekleşen ilk halka arzların kısa ve uzun dönem getirileri üzerinde; haftanın günü(the day of the week effect), yılın ayı(the month of the year effect), ayın haftası(the week of the month effect), ayın belirli haftasının günü(the weekday of the month effect), yılın ilk ya da ikinci yarısı(the semi year effect), ayın ilk ya da ikinci yarısı(the semi month effect) ve ay dönüşü(turn of the month effect) takvim anomalilerinin etkili olduğuna yönelik kanıtlar bulunmuştur.

Bilindiği gibi uzun dönem performans araştırmalarında çoğunlukla doğrusal regresyon yöntemi kullanılmaktadır. Oysaki literatür insan zekâsına dayalı yaklaşımların, örüntü tanıma, sınıflandırma ve eşleştirme konusunda daha iyi sonuçlar ortaya koyabileceğini işaret etmektedir.

Yapay sinir ağı teknolojisi de insan beyninin bilgi işleme yeteneğinden yola çıkılarak elde edilen bir teknolojidir ve örüntü tanıma konusunda oldukça yeteneklidir (Haykin, 1999).

Halka arz getirilerinin tahmininde yapay sinir ağı teknolojisinden yararlanan öncü çalışmalar olarak; Jain ve Nag (1995), Jain ve Nag (1998) sayılabilir.

Jain ve Nag (1995) ilk çalışmalarında yapay sinir ağı modelinin halka arz edilen işletmelerin ikincil piyasadaki fiyatını tahmin etmeyi amaçlamışlardır. Yapay sinir ağı modeli ikincil piyasadaki kayıpları minimuma indiren yöntem olmuştur. Robertson, Golden, Runger, Wasil (1998), Jain ve Nag (1995) tarafından yapılan çalışmanın bir benzerini ilk gün getirisini tahmin edecek şekilde yapmışlardır. Reber, Berry, Toms (2005) yapay sinir ağının halka arz edilen hisse senetlerinin getirisinin yönünü doğrusal regresyondan daha iyi tahmin edip edemeyeceğini araştırmışlardır. Geliştirilen yapay sinir ağı modelleri getirinin yönünü doğrusal regresyondan daha iyi tahmin etmişlerdir.

Jain ve Nag(1998) yaptıkları ikinci bir çalışmada halka arz edilen şirketlerin uzun dönemdeki performansını inceleme konusu yapmışlardır. İlk defa halka arz edilen hisse senetleri ile ilgili en önemli problem, bu hisselerin uzun dönemli performansını tahmin etmektir. Çünkü bu hisse senetleri daha önce borsada işlem görmedikleri için geçmiş fiyat hareketleri bulunmaz. Bu hisselerin ait oldukları işletmelerin temel analizde kullanılacak bilgileri de kısıtlıdır. Çünkü ilk defa halka arz sırasında bu işletmelere ait çok kısa dönemli finansal bilgiler açıklanır. Her ne kadar halka açılma sırasında piyasa düzenleyici kurumların bazı standartları bulunsun da, bu işletmelerin halka açık olmadıkları dönemdeki muhasebe bilgilerine güven duyulmaz. Bu bilgiler eksik, yanlış ve hatta yanıltıcı olabilirler. Böyle bir ortamda ilk defa halka arz edilen işletmelerin uzun dönemli performanslarını tahmin etmek



oldukça güç bir problem olabilmektedir. Jain ve Nag (1998) halka arz edilen şirketlerin uzun dönemli performansını tahmin etmek amacıyla yapay sinir ağını kullanan ilk araştırmadır. Araştırmada yapay sinir ağının yanında istatistiksel araçlardan lojitten de yararlanarak ilk defa halka arzı gerçekleştirilen işletmelerin uzun dönemli performansını yüksek ve düşük şeklinde ikili bir sınıflandırma yapılmıştır.

Fakat halka arz performansına göre şirketleri sınıflandırmak kendine özgü zorlukları olan bir problemdir. Halka açılan işletmelerin uzun dönemli performansları çok sayıda ve bir biri ile ilişkili değişkene bağlıdır. Bağımsız değişkenlerin bağımlı değişken ile ilişkileri tam ve net olarak belirlemek çok zordur. Yapay sinir ağının sahip olduğu avantajlar nedeniyle istatistik tekniklerden daha üstün performans sergilemesi beklenmektedir. Jain ve Nag (1998) halka arz edilen şirketlerin uzun dönemli kazandıran veya kaybettiren gruplarından hangisine gireceğini yapay sinir ağı tahmin etmişler ve performansını, lojit ile karşılaştırmışlardır.

Araştırma örneklemini 1976–1988 yılları arasında halka açılan şirketlerden oluşmaktadır. Araştırmada daha önce literatürde önerilen değişkenler kullanılmıştır. Bu değişkenler halka arz büyüklüğü, aracı kuruluşun itibarı, halka arz fiyatı, başlangıç fiyatı, işletmenin riski, halka açılmamış kısmının toplama oranı, halka açılmadan önceki yıla ait finansman giderlerinin varlıklara oranıdır. Örneklemdaki 134 işletme yüksek performans sergileyen işletme, kalan 327 işletme düşük performans sergileyen işletme olarak kabul edilmiştir (Jain ve Nag, 1998). Yapay sinir ağı ilk defa halka arz edilen hisse senetlerinin uzun dönem getiri yönünü %69,26 oranında doğru tahmin ederken, lojit modelinin en iyi performans sergileyen kopma noktasına göre (0,50) performansı %68,83 olmuştur.

3. Veri ve Yöntem

Bu çalışma 1992–2005 döneminde ilk halka arz edilen 136 firmayı kapsamaktadır. Örneklem periyodunun 1992'den başlamasının nedeni daha önceki yıllara ait sağlıklı bilanço verilerine ulaşılamamasıdır. Çalışmanın 2005 yılında bitirilmesinin nedeni ise uzun dönem performans için 36 aylık veri kullanılmasından kaynaklanmaktadır. Şöyle ki 2005 yılında halka arz edilen bir firma için 2008 yılı verilerine ihtiyaç duyulmaktadır. Çalışmada kullanılan değişkenlerin önceki çalışmalarda sıklıkla kullanılan değişkenler olmasına dikkat edilmiştir. Modelde kullanılan değişkenlerle ilgili veriler İMKB'den temin edilmiş olup hesaplanma şekilleri ise Tablo 1'de verilmiştir;



Tablo 1
Modellerde Kullanılan Bağımlı ve Bağımsız Değişkenler

Bağımsız değişkenler¹	
Hesaplanma Şekli	
İlk Gün	Firmanın ilk halka arz edildiği günkü getirileridir. Ham getiriler hesaplandıktan sonra doğrusal regresyon piyasa modeli (market model) ile tahmin edilmiştir.
Halka Arz Fiyatı	Firmanın halka arz fiyatının doğal logaritmasıdır.
Hasılat	Firmanın elde ettiği hasılatın dolar cinsinden değerinin logaritmasıdır.
Aracılık Yüklenimi	Firmanın aracılık yüklenimi olarak, en iyi gayret aracılığı ve bakiyeyi yüklenim seçeneklerini tercihine göre kukla değişken olarak kullanılmıştır.
Satış Yöntemi	Firmanın halka arz edilirken kullandığı satış yöntemidir. Sabit fiyatla, fiyat aralığı(fiyat teklifi) ve borsada satış yöntemini kullanmasına göre kukla değişken olarak belirlenmiştir.
Bağımlı değişkenler²	
MBHR	Piyasaya göre düzeltilmiş 36 aylık satın al ve elde tut getirileridir. Öncelikle ham getiriler hesaplandıktan sonra doğrusal regresyon piyasa modeli (market model) ile tahmin edilmiştir.
CAR	Piyasaya göre düzeltilmiş 36 aylık kümülatif getirilerdir. Öncelikle ham getiriler hesaplandıktan sonra doğrusal regresyon piyasa modeli (market model) ile tahmin edilmiştir.

¹ Doğrusal regresyon tahmini için 15(Yaş, Varlık, D/E, İlk Gün, Sabit Fiyat, Fiyat Aralığı, Borsada Satış, En İyi Gayret Aracılığı, Bakiyeyi Yüklenim, Ortak Satışı, Sermaye Artırımı, Ortak Satışı ve Sermaye Artırımı, Hasılat, Halka Arz Oranı, Halka Arz Fiyatı) tane açıklayıcı değişken kullanılarak model tahmin edilmeye başlanmıştır. En büyük anlamsız katsayı yani değişkenler tek tek atılmış ve model her seferinde yeniden tahmin edilerek en uygun modele ulaşılmıştır. (Tablo2-Tablo3) Bu kapsamda Tablo 1' de ise bağımsız değişkenlere ilişkin ayrıntılı bilgiler raporlanmıştır.

Tablo-1'de yer almayan bağımsız değişkenler ve hesaplanma biçimleri şu şekildedir: Yaş(Firmanın kuruluşundan halka arz edildiği süreye kadar geçen zamanın, faaliyet süresinin doğal logaritmasını ifade eder), Varlık(Firmanın halka arz edilmeden önceki yılki varlıklarının dolar cinsinden değerinin doğal logaritmasıdır), D/E(Firmanın halka arz edilmeden önceki yılki borç/özsermaye oranıdır), Halka arz oranı(Firmanın halka arz oranıdır).

² Uzun dönem anormal getirilerin (CAR ve MBHR) piyasa modeli(market model) ile hesaplanabilmesi için öncelikle uzun dönemli ham ve kümülatif getiriye ihtiyaç duyulmaktadır. Ham getiri (R_{it}) ve piyasa getirisi

(R_{mt}) [$(P_t / P_{t-1}) - 1$] formülü ile hesaplanmıştır. Kümülatif ham getiriler ($\sum_{t=1}^n R_{it}$) formülü ile satın al ve elde tut ham getiriler ise [$(P_t / P_{t-36}) - 1$] formülü ile hesaplanmıştır.



Bu çalışmada uzun dönem getiriler CAR ve MBHR olmak üzere iki alternatif yaklaşımla tespit edilmiştir (Barber ve Lyon, 1997; Kothari ve Warner, 1997; Lyon vd. 1999). Literatürde anormal getirilerin hesaplanmasıyla ilgili çeşitli problemler bulunmaktadır. Daha önceki çalışmalar incelendiğinde anormal getirilerin hisse senedinin getirisinden piyasanın getirisinin çıkarılmasıyla elde edildiği görülmektedir (Ritter, 1991; Levis, 1993; Kıymaz, 1996, 1997). Fakat son zamanlarda anormal getirilerin doğrusal regresyon yöntemiyle hesaplanmasının daha iyi sonuçlar vereceği düşünülmektedir. Bu amaçla bu çalışmadaki anormal getiriler piyasa modeli (market model) yöntemi kullanılarak elde edilmiştir (Campbell, Lo ve MacKinlay, 1997: 158);

$$R_i = X_i' \theta_i + \varepsilon_i \quad [1]$$

Bu modelde $R_i = \{ R_{iT_0+1}, \dots, R_{iT_i} \}$ tahmin aralığındaki getiriler vektörünü, X_i ise birinci sütununda birler vektörünün, ikinci sütununda ise piyasa getirilerinden oluşan getiri vektörünün $R_m = \{ R_{mT_0+1}, \dots, R_{mT_i} \}$ oluşturduğu bir matristir.

$\theta_i = \{ \alpha_i, \beta_i \}$ ise (2×1) parametre vektörüdür. Piyasa modelinin tahmininde genel varsayımların geçerliliği halinde tutarlı sonuçlar veren doğrusal regresyon modeli kullanılmıştır. Doğrusal regresyon modeline göre parametre tahmini aşağıdaki gibidir:

$$\hat{\theta}_i = (X_i' X_i)^{-1} X_i' R_i \quad [2]$$

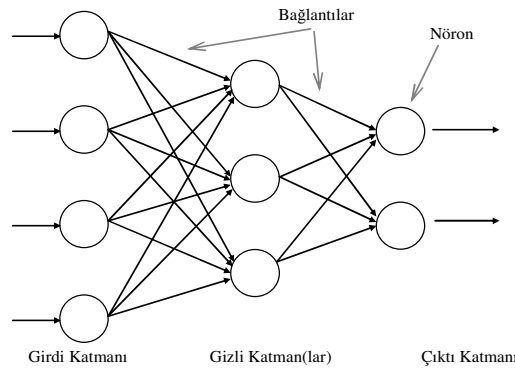
$$\hat{\varepsilon}_i = R_i - X_i \hat{\theta}_i \quad [3]$$

Bu çalışmada uzun dönemli getirileri tahmin etmek için doğrusal regresyon ve yapay sinir ağı ile iki farklı model geliştirilmiş ve modellerin tahmin güçleri karşılaştırılmıştır. Geliştirilen modellerin performansları, MSE'leri (Hata Karelerinin Ortalamasının) temel alınarak karşılaştırılmıştır.

3.1. Yapay Sinir Ağı

Yapay sinir ağı, insan beyninin çalışma şekline öykünen bir bilgi işlem yöntemidir. Yapay sinir ağı, bir biri ile bağlantılı basit işlemcilerden oluşan bir ağıdır. Bu işlemcilere sinir düğümü veya nöron adı verilir.

Yapay sinir ağı modeli



Her işlemci, başka işlemcilere bağlantılar aracılığı ile ilişkilendirilmiştir. Bu bağlantıların üzerinden veri akışı sağlanır ve her biri bir ağırlık değerine sahiptir. Bu işlemcilerin iki temel işlevi vardır: İlk olarak bağlantılar aracılığı ile kendilerine ulaşan verilerin, geldiği bağlantının ağırlık değerini de kullanarak, ağırlıklı toplamını alır. İkinci olarak elde edilen bu ağırlıklı toplamın, önceden belirlenmiş bir eşik değeri aşp aşmadığı kontrol edilir. Eğer eşik değeri aşılmışsa çıktı üretilir, eğer aşılmamışsa herhangi bir çıktı üretmez. Yapay sinir ağının öğrenmesi, bir öğrenme algoritmasının, verilen girdiler için istenen çıktıların üretildiği bir duruma gelinceye kadar, ağın içindeki ağırlıkların değiştirilmesi ile sağlanır. Bu durumda yapay sinir ağı girdi ve çıktılar arasındaki ilişkiyi öğrenmiş olur ve gerçek modeli taklit etmeye başlar.



Literatüre göre, bir yapay sinir ağı modeli, sahip olduğu gizli katman sayısına göre farklı istatistiksel yetenekler sergilemektedir. Örneğin gizli katmanı olmayan bir yapay sinir ağı modeli girdi uzayını bir düzlem ile ikiye ayırmaktadır. Bu ayırma analizinin yeteneklerine eş değerdir. Tek gizli katmana sahip bir yapay sinir ağı ise, girdi uzayını iki veya daha fazla düzlemle açık veya kapalı, içbükey veya dışbükey bölgelere ayırabilmektedir. Eğer bir yapay sinir ağı iki veya daha fazla gizli katmana sahip ise, girdi uzayını parçalı bir şekilde içbükey veya dışbükey olarak bölebilmektedir. Parça sayısı katmanlardaki nöron sayısına bağlı olarak değişmektedir (Bishop, 1999). Yapay sinir ağının sahip olduğu gizli katman sayısı ve bu gizli katmandaki işlemci sayısı, yapay sinir ağının istatistiksel yeteneklerini belirlemektedir. Katman sayısı ve bu katmandaki işlemci sayısı arttıkça, yapay sinir ağı daha karmaşık modelleme yeteneğine kavuşmaktadır.

Bir yapay sinir ağı modelinin geliştirilmesi sırasında mimari, öğrenme algoritması, hata türü, verilerin kodlanması konusunda bazı kararlar verilmesi gerekmektedir. Uygun bir yapay sinir ağı modeli geliştirmek için bazı öneriler bulunmakla beraber, ne yazık ki, bir problemin çözümünde kullanılacak standart bir yöntem bulunmamaktadır. Bir problemin çözümü için en uygun mimari, öğrenme algoritması, hata türü, verilerin kodlama şekli ancak deneme yanılma yoluyla bulunmaktadır. Bir durum yapay sinir ağı teknolojisinin önemli dezavantajlarından biri olarak karşımıza çıkmaktadır. Bu çalışmada da uygun modeli bulmak için deneme yanılma şeklinde bir süreçten geçilmiştir.

Yapay sinir ağının mimarisine karar verilirken, öncelikle girdi ve çıktı katmanında yer alacak işlemci sayısı belirlenmiştir. CAR doğrusal regresyon modeli rekabetçi model olarak kabul edildiği için, yapay sinir ağı modellerinde girdi olarak, CAR doğrusal regresyon modelinde kullanılan üç değişken kullanılmıştır. Bunlar Fiyat Teklifi, İlk Gün ve Halka Arz Fiyatı değişkenleridir. Yapay sinir ağının girdi katmanı 3 işlemci içermektedir. CAR bağımlı



İlk Halka Arz. Uzun Dön. Get. Tahmini: Yap. Sinir Ağları ile İMKB için Amp. Bir Çalışma

değişkenini hesaplayan bir yapay sinir ağı modeli geliştirilmiştir. Bir başka deyişle yapay sinir ağının çıktı katmanında, CAR bağımlı değişkenin değerini hesaplayan tek bir işlemci bulunmaktadır. Çalışmada ThinksPro (Ver 1.05) adlı yazılım kullanılmıştır (www.logicaldesings.com).

Yapay sinir ağı geliştirilirken mimari ile ilgili bir başka önemli karar, gizli katman sayısının belirlenmesidir. Bu çalışmada geliştirilen yapay sinir ağı modelleri için tek gizli katman kullanımı tercih edilmiştir. Literatür incelendiğinde birden fazla gizli katmanla çözülen problem yok gibidir ve yaygın bir görüşe göre, tek gizli katmanlı bir yapay sinir ağının karşılaşılan problemlerin büyük bir kısmının çözümü için yeterlidir (Yıldız, 2009).

Gizli katmanda kaç adet işlemci kullanılacağını belirlemek için değişik stratejiler bulunmaktadır. Bu stratejilerden biri geniş bir ağ ile başlamak ve ağın genelleme yeteneğinde bir düşme meydana gelinceye kadar, gizli katmandaki işlemci sayısını azaltmaktır. Bunun için değişik sayılardaki yapay sinir ağı modelleriyle deneme-yanılmalar gerçekleştirmek ve ağın genelleme yeteneğindeki değişimleri gözlemlemek gerekir. Gizli katmandaki gereksiz işlemciler yapay sinir ağının genelleme yapmak yerine, verileri ezberlemesine neden olabilmektedir. Bu deneme yanılma sürecinde toplamda 18 model geliştirilmiştir. Yapay sinir ağı modeli geliştirilirken eğitim verilerindeki hata ve test verilerindeki hata grafiği sürekli izlenerek, yapay sinir ağı modelinin uygun genelleştirme düzeyine ulaşıp ulaşamadığı kontrol edilmiştir. Eğitim verilerindeki hata düzeyinin düşmeye devam ettiği, ancak test verilerindeki hata grafiğinde artış olduğu durumlarda, ezberlemenin ortaya çıkması nedeniyle modelin eğitime son verilerek, yeni model denemelerine girişilmiştir. Ayrıca eğitim verilerindeki hatada düşme eğiliminin durduğu ve hata grafiğinde yatay eksenine paralel olarak hareket etmeye başladığı durumlarda da eğitim durdurulmuştur.

Yapay sinir ağı ile CAR tahmini için geliştirilen 18 modelden en iyi performansı gösteren model Tablo 2' de raporlanmıştır:



Tablo 2

<i>Mimari</i>	İleri beslemeli
<i>Hata Hesaplaması</i>	MSE
<i>Öğrenme Algoritması</i>	Jacob Geri Yayılım Algoritması ³
<i>Girdi Katmanı</i>	(3 işlemci, Ortalama / Standart Sapma Normalleştirme işlemi yapılmıştır)
<i>Gizli Katman</i>	1 (2 işlemci, Sigmoid +/- transfer fonksiyonu)
<i>Çıktı Katmanı</i>	(işlemci, Sine +/- transfer fonksiyonu)
<i>Döngü sayısı</i>	2942

Tablo 2' deki yapay sinir ağı modeli, MBHR bağımlı değişkeni için de en başarılı tahmini gerçekleştiren yapay sinir ağı modeli olmuştur.

Doğrusal regresyon ve yapay sinir ağı modelinin geliştirilmesi için, çalışmanın örneklemini oluşturan 136 firmanın 100 adedi kullanılırken, kalan 36 firma, geliştirilen modellerin tahmin güçlerini ölçülmek için kullanılmıştır. Örnekleme geriyeye kalan 36 gözlem test için kullanılarak modellerin performansları karşılaştırılmıştır.

4. Bulgular

Araştırmada CAR ve MBHR modelleri için elde edilen doğrusal regresyon modelleri aşağıda Tablo3 ve Tablo 4'de görülmektedir.

³ Kullanılan Jacobs Enhanced Back Propagation Learning Rule için bakınız: R.A. Jacobs (1988), "Increased Rates of Convergence Through Learning Rate Adaptation", *Neural Networks*, 1, ss.295-307 ve ThinkPro User Handbook (1995), Logical Designs Inc.,CA.



Tablo 3
CAR için OLS yatay kesit (cross-section) tahmin sonuçları

Değişken	Katsayı
<i>Sabit terim</i>	3.3022 (2.3796)**
<i>Satış Yöntemi^a</i>	0.36172 (1.7026)*
<i>İlk Gün</i>	0.9223 (5.1257)***
<i>Halka arz fiyatı</i>	-0.3293 (-2.4017)**
<i>White Test F</i>	1.691 [0.144]
<i>Ramsey Reset F₍₁₎[#]</i>	0.042 [0.837]
<i>Ramsey Reset F₍₄₎[#]</i>	0.663 [0.619]
<i>Ramsey Reset F₍₆₎[#]</i>	1.862 [0.095]
<i>R₂:0.285</i>	
<i>SSR: 95.4820</i>	

Parantez içindeki değerler t istatistikleri, köşeli parantez içindeki değerler ise prob. değerleridir.

[#] Farklı uygunluk değerleri (number of fitted term) için test sonuçlarıdır. %5 anlam düzeyine göre ekonometrik modelin spesifikasyon hatası yoktur ($F_{\text{Hesaplanan}} > F_{\text{Tablo}}$)

(*) katsayı %10 anlam düzeyinde anlamlıdır

(**) katsayı %5 anlam düzeyinde anlamlıdır

(***) ise katsayı %1 anlam düzeyinde anlamlıdır

^a Satış yöntemi olarak sadece fiyat aralığı (fiyat teklifi) kullanılmıştır. Borsada satış ve sabit fiyat seçeneği anlamlı olmadığı için elimine edilmiştir.

Tablo 4
MBHR için OLS yatay kesit (cross-section) tahmin sonuçları

<u>Değişken</u>	<u>Katsayı</u>	<u>NW' e göre standart hatalar</u>	
		<u>Düzeltilmiş</u>	<u>Düzeltilmemiş</u>
<i>Sabit terim</i>	0.1090 (0.2625)	0.4627	0.4152
<i>Aracılık yüklenimi^b</i>	-0.7802 (-1.8591)*	0.4024	0.4196
<i>Hasılat</i>	0.0505 (2.2034)**	0.0274	0.0229
<i>İlk Gün</i>	0.5297 (1.9999)**	0.2154	0.2648
White Test F	5.883 [0.000] [%]		
Ramsey Reset F₍₁₎[#]	2.651 [0.106]		
Ramsey Reset F₍₄₎[#]	2.089 [0.088]		
Ramsey Reset F₍₆₎[#]	1.763 [0.115]		
R2:0.103			
SSR: 137.2656			

Parantez içindeki değerler t istatistikleri, köşeli parantez içindeki değerler ise prob. değerleridir.

[#] Farklı uygunluk değerleri (number of fitted term) için test sonuçlarıdır. %5 anlam düzeyine göre ekonometrik modelin spesifikasyon hatası yoktur ($F_{Hesaplanan} > F_{Tablo}$)

(*) katsayı %10 anlam düzeyinde anlamlıdır

(**) katsayı %5 anlam düzeyinde anlamlıdır

(***) ise katsayı %1 anlam düzeyinde anlamlıdır

% white testi değişen varyans problemini işaret etmektedir. Bu kapsamda Newey-West düzeltmesi uygulanmış ve t istatistikleri Newey-West e göre yeniden ayarlanmış halleriyle raporlanmıştır.

^b Aracılık yüklenimi olarak sadece bakiyeyi yüklenim kullanılmıştır. en iyi gayret aracılığı seçeneği anlamlı olmadığı için elimine edilmiştir. Bakiyeyi yüklenim en iyi gayret aracılığı tercihinine göre oluşturulan kukla değişken olarak kullanılmıştır.

Aşağıdaki Tablo 5’de CAR ve MBHR için geliştirilen doğrusal regresyon modelleri ile yapay sinir ağı modellerinin tahmin başarıları görülmektedir.

Tablo 5
Doğrusal regresyon ve yapay sinir ağı modellerinin getiri tahmin performansı

	CAR			MBHR		
	<i>Doğrusal Regresyon</i>	<i>Yapay Sinir Ağı</i>	<i>t</i>	<i>Doğrusal Regresyon</i>	<i>Yapay Sinir Ağı</i>	<i>t</i>
SSE	19,37	11,35		28,08	24,13	
MSE	0,53	0,31	1,62*	0,78	0,67	1,86*

(*)%10 anlam düzeyinde anlamlıdır



Tablo 5’de yapay sinir ağının hem CAR hem de MBHR modeli için SSE ve MSE⁴ şeklindeki üç hata türüne göre de doğrusal regresyon modelinden daha iyi sonuçlar ürettiği görülmektedir.

5. Sonuç

Yatırımcılar için ilk defa halka arzı yapılan hisse senetlerinin performanslarını tahmin etmek, iyi bir yatırım kararının önemli koşullarındandır. Literatürde ilk defa halka arz edilen hisse senetlerinin kısa ve uzun dönemde performanslarını tahmin etmek için yaygın olarak doğrusal regresyon kullanılmaktadır. Bu çalışmada İMKB’de ilk halka arzı gerçekleştirilen hisse senetlerinin uzun dönemli performansının tahmin edilmesi amacıyla yapay sinir ağı kullanılmıştır. Eldeki bulgular yapay sinir ağı ile geliştirilen modelin doğrusal regresyon modelinden daha iyi tahmin yaptığını ortaya koymaktadır. Bu sonuç diğer piyasalarda yapay sinir ağı ile ilgili yapılmış çalışmalarla uyumludur.

⁴ İki modele ait MSE’ ler arasındaki farkın istatistiksel olarak anlamlı olup olmadığı t testi ile test edilmiştir. Yapay sinir ağı ve doğrusal regresyon modellerinden gelen MSE’ ler istatistiksel olarak birbirinden farklıdır ve yapay sinir ağı ile geliştirilen model doğrusal regresyon modelinden daha iyi tahmin yapmaktadır.



Kaynaklar

- Aggarwal, R. ve Rivoli, P. (1990), "Fads in initial public offering market", *Financial Management* 19, ss.45-57.
- Aggarwal, R., Leal, R. ve Hernandez, L. (1993), "The Aftermarket Performance of Initial Public Offerings in Latin America", *Financial Management* 22, ss.42-53.
- Alexander, J. (1993), "The lawsuit avoidance theory of why Initial Public Offerings are underpriced", *UCLA Law Review* 41, ss.17-73.
- Ayden T. ve Karan, M.B. (2000), "İstanbul Menkul Kıymetler Borsasında İlk Halka Arzların Uzun Vadeli Fiyat Performanslarının Ölçülmesi", *Gazi Üniversitesi İ.İ.B.F Dergisi* 2 (3), ss.87-96.
- Barber, B.M. ve Lyon, J.D. (1997), "Detecting long-run abnormal stock returns: the empirical power and specification of test statistics", *Journal of Financial Economics* 43, ss.341-372.
- Baron, D.P. (1982), "A model of the demand for investment bank advising and distribution services for new Issues", *Journal of Finance* 45, ss.1045-1067.
- Bernardo, A.E. ve Welch, I. (2001), "On the Evolution of Overconfidence and Entrepreneurs", *Journal of Economics and Management Strategy* 10, ss.301-330.
- Bishop C. M. (1997), "Neural Netorks for Pattern Recognition", Clarendon Press, Oxford, ss.122-124.
- Boardman, A. ve Laurin, C. (2000), "Factors affecting the stock price performance of share issued privatizations", *Applied Economics*, 32(11), ss.1451-1464.
- Brav, A., Geczy, C. ve Gompers, P.A. (2000), "Is the abnormal return following equity issuances anomalous?", *Journal of Financial Economics* 56, ss.209-249.
- Brav, A. ve Gompers, P.A. (1997), "Myth or reality? The long-run underperformance of initial public offerings: Evidence from venture and non-venture capital-backed companies", *Journal of Finance* 52, ss.1791-1821.
- Cai, J. ve Wei, K.C. (1997), "The investment and operating performance of Japanese initial public offerings", *Pacific-Basin Finance Journal* 5, ss.389- 417.
- Campbell, J.Y. Lo, A.E. ve Mackinlay, A.C. (1997), "The econometrics of financial markets", Princeton University Press, Princeton, New Jersey.
- Carter, R. ve Manaster, S. (1990), "Initial public offerings and underwriter reputation", *The Journal Of Finance*, 45(4), ss.1045- 1067.
- Carhart, M. (1997), "On Persistence in Mutual Fund Performance", *Journal of Finance* 52, ss.57-82.
- Carter, R.B. Dark, F.H. ve Singh, A.K. (1998), "Underwriter Reputation, Initial Returns, and the Long-run Performance of IPO Stocks", *Journal of Finance* 53, ss.285-311.
- Chalk, A.J., ve Peavy, J.W. (1987), "Initial public offerings: Daily returns, offering types and the price effect", *Financial Analysts Journal* 43(5), ss.65-69.
- Daniel, K. Hirshleifer, D. ve Subrahmanyam, A. (1998), "Investor psychology and security market under- and overreactions", *Journal of Finance* 53, ss.1839-1885.
- Dewenter, K.L. ve Malatesta, P.H. (1997), "Public offerings of state-owned and privately owned enterprises : An international comparison", *Journal of Finance* 52, ss. 1659- 1679.
- Durukan, M.B. (2002), "The relationship between IPO returns and factors influencing IPO performance: Case of the Istanbul Stock Exchange" *Managerial Finance* 28, ss.18-38.



- Eckbo, B.E. ve Norli, Ø. (2005), “Liquidity Risk, Leverage and Long-Run IPO Returns”, *Journal of Corporate Finance* 11, ss.1-35.
- Fama, E.F. ve French, K.R. (1993), “Common risk factors in the returns on stocks and bonds”, *Journal of Financial Economics* 43, ss.3-56.
- Firth, M. (1997), “An analysis of the stock market performance of new issues in New Zealand”, *Pacific-Basin Finance Journal* 5, ss.63-85.
- Haykin, S. (1999), “Neural Networks”, Prentice Hall, Second Edition, N.J.
- Heaton, J. (2002), “Managerial Optimism and Corporate Finance”, *Financial Management* 31, ss.33-45.
- Ikoku, A.E. (1998), “Influence-seeking and pricing of initial public offerings and privatizations: Evidence from the Nigerian Equity Market”, University of Southern California, Working Paper.
- Jain, B.A. ve Kini, O. (1994), “The Post-Issue Operating Performance of IPO Firms”, *Journal of Finance* 49, ss.1699-1726.
- Jain B.A. ve Nag, B.N. (1998), “A neural network model to predict long-run operating performance of new ventures”, *Annals of Operations Research* 78, ss.83–110.
- Jain B.A. ve Nag, B.N. (1995), “Artificial neural network models for pricing initial public offerings”, *Decision Sciences* 26(3), ss.283–302.
- Jenkinson, T. ve Ljungqvist, A. (2001), “Going Public: The Theory and Evidence on How Companies Raise Equity Finance”, 2nd Edition, Oxford University Press, Oxford, UK.
- Jog, V. (1997), “The climate for Canadian initial public offerings”, *Financing Growth in Canada*, University of Calgary Press, Calgary, ss.357-401.
- Kıymaz, H. (1997a), “İMKB’de halka arz edilen hisse senetlerinin uzun dönem performansları ve bunları etkileyen faktörler: İmalat sektörü 1990-1995 uygulaması”, *İMKB Dergisi* 3, ss.47-73.
- Kıymaz, H. (1997b), “İMKB’de halka arz edilen mali sektör hisse senetlerinin uzun dönem performansları: 1990-1995 uygulaması”, *Hazine Dergisi* 7, ss.1-18.
- Kıymaz, H. (2000), “The initial and aftermarket performance of IPOs in an emerging market: evidence from Istanbul Stock Exchange”, *Journal of Multinational Financial Management* 10, ss.213- 227.
- Kim, B.J. Krinsky, I. ve Lee, J. (1995), “The aftermarket performance of initial public offerings”, *Pacific-Basin Journal* 3, ss.429-448.
- Kothari, S.P. ve Warner, J.B. (1997), “Measuring long-horizon security price performance”, *Journal of Financial Economics*, ss.301- 339.
- Kunz, R.M. ve Aggarwal, R. (1994), “Why initial public offerings are underpriced: Evidence from Switzerland”, *Journal of Banking and Finance* 18, ss.705-723.
- Lee, P.J. Taylor, S.L. ve Walter, T.S. (1996), “Expected and realized returns for Singaporean IPOs: Initial and long-run analysis”, *Pacific-Basin Journal* 4, ss.153–180.
- Levis, M. (1993), “The long-run performance of IPOs: the UK experience 1980–1988”, *Financial Management Spring* 22, ss.28-41.
- Ljungqvist, A. (1997), “Pricing initial public offerings: Further evidence from Germany”, *European Economic Review* 41, ss.1309-1320.



- Ljungqvist, A. (2003), "Conflicts of interest and efficient contracting in IPOs", *NYU, Ctr for Law and Business Research Paper No. 03-03*, Working paper series.
- Ljungqvist, A.P. ve Wilhelm, W.J. (2003), "IPO Pricing in the Dot-Com Bubble", *Journal of Finance* 58, ss.723-752.
- Loughran, T. Ritter, J.R. ve Rydqvist, K. (1994), "Initial public offerings: International insights", *Pacific-Basin Finance Journal* 2, ss.165-199.
- Loughran, T. ve Ritter, J.R. (2000), "Uniformly least powerful tests of market efficiency", *Journal of Financial Economics* 55, ss.361-389.
- Loughran, T ve Ritter, J.R. (2004), "Why Has IPO Underpricing Changed Over Time?", *Financial Management* 33(3), ss.5-37.
- Lyon, J.D. Barber, B.M. ve Tsai, C.L. (1999), "Improved methods for tests of long-run abnormal stock returns", *Journal of Finance* 54, ss.165-201.
- Mikkelsen, W.H. Partch, M. ve Shah, K. (1997), "Ownership and operating performance of companies that go public", *Journal of Financial Economics* 44(3),ss. 279-307.
- Özer, B. (1999), "Price performance of initial public offerings in Turkey", Sermaye Piyasası Kurumu Yayınları, Yayın No: 128, Ankara.
- Raghuram R. ve Servaes, H. (1997), "Analyst Following of Initial Public Offerings", *Journal of Finance* 52(2), ss.507-29.
- Reber, B. Berry, B. ve Toms, S. (2005), "Predicting mispricing of initial public offerings. Intelligent systems in accounting", *Finance and Management*, (13), ss.41-59.
- Ritter, J.R. (2003), "Differences between European and American IPO markets", *European Financial Management* 9(4), ss.421-434.
- Ritter, J.R. (1991), "The long-run performance of initial public offerings", *Journal of Finance* 42, ss.365-94.
- Ritter, J.R. ve Welch, I. (2002), "A review of IPO activity, pricing, and allocations", *Journal of Finance* 57, ss.1795-1828.
- Ritter, J.R. (2005), "Economic Growth and Equity Returns", *Pacific-Basin Finance Journal* 13(5), ss.489-503.
- Robertson S.J. Golden B.L. Runger G.C. ve Wasil E.A. (1998), "Neural network models for initial public offerings", *Neurocomputing* 18, ss.165-182.
- Tinic, S. (1988), "Anatomy of initial public offerings of common stock", *Journal of Finance* 43, ss.789-822.
- Weiss, H.K. (1993), "The underpricing of initial public offerings and the partial adjustment phenomenon", *Journal of Financial Economics* 34(2), ss.231-250.
- Ünlü, U., ve Ersoy, E. (2008), "İlk halka arzlarında düşük fiyatlama ve kısa dönem performansın belirleyicileri", *Dokuz Eylül Üniversitesi İİBF Dergisi*, 23(2), ss.243-258.
- Yalama, A., ve Ünlü, U.(2010), "The calendar anomalies in IPO returns: Evidence from Turkey", *İktisat İşletme ve Finans* 25 (286), ss.89-109.
- Yıldız, B. (2009), "Finansal Analizde Yapay Zeka", Detay Yayınları, Ankara, ss.107-118.