

Nakit Temettü Tahmininde Makine Öğrenmesi Yaklaşımı: İmalat Sektörü Üzerine Bir Araştırma

Mustafa Fatih ARSOY

Sorumlu Yazar, Kara Harp Okulu, İşletme Bölümü, mfarsoy@kho.edu.tr

Erkam GÜREŞEN

Kara Harp Okulu, Endüstri ve Sistem Mühendisliği Bölümü, eguresen@kho.edu.tr

Öz

Sermaye piyasalarında yapılacak yatırım kararlarını doğrudan etkileyen bir faktör olan temettü dağıtımını, işletmenin geçmiş performansını gösterdiği kadar gelecekteki performansı hakkında da ipuçları vermektedir. Bu çalışmada Türkiye’de halka açık işletmeler tarafından dağıtılan temettülerin tahmininde Marsh&Merton (M&M) modelinin kullanılabilirliğinin test edilmesi ve makine öğrenme tekniklerini uygulayarak, M&M’den daha iyi bir model geliştirilmesi amaçlanmıştır. Araştırmada nakit dağıtılan temettü oranı tahmininde Borsa İstanbul (BİST)’da işlem gören imalat sektöründeki 139 işletmenin 2003-2012 yılları arasındaki verileri kullanarak M&M modeli ile makine öğrenme tekniğine dayalı Çok Katmanlı Algılayıcı (Bir ve İki Gizli Katmanlı ÇKA), Radyal Tabanlı Fonksiyon Ağları (RTFA), Destek Vektör Makineleri (DVM) ve Adaptif Sinirsel Bulanık Çıkarsama Sistemleri (ASBÇS) şeklinde beş farklı model karşılaştırılmıştır. Genel olarak RTFA modelinin M&M modeline yakın sonuçlar ürettiği, ÇKA modellerinin düşük miktarda dağıtılan temettüleri tahmin edemediği, DVM modelinin ise M&M’den daha kötü sonuçlar verdiği görülmüştür. Çalışma sonucunda ASBÇS modelinin temettü tahmininde en başarılı yöntem olduğu tespit edilmiştir.

Anahtar Kelimeler: Nakit Temettü Tahmini, Marsh Merton Modeli, ASBÇS, RTFA, ÇKA, DVM.

JEL Sınıflandırma Kodları: G35, C53, G17.

A Machine Learning Approach for Cash Dividends’ Forecasting: A Research on Manufacturing Sector*

Abstract

Dividend payment is a factor that affects investment decisions in capital markets. Although dividend payments indicate past performance of corporate, they also give some clues about company’s future performance. In this study, feasibility of Marsh&Merton (M&M) model is tested in Turkey tried to develop a better model than M&M model by applying machine learning techniques. For this study payout ratios between 2003 and 2012 from 139 manufacturing companies which are quoted on ISE are selected. M&M model and five machine learning models namely Multi-Layer Perception (MLP), Radial Based Function Networks (RBFN), Support Vector Machines (SVM) and Adaptive Neuro-Fuzzy Inference Systems (ANFIS) are compared with each other. Generally it is occurred that RBFN models produces similar results with M&M model, MLP models cannot forecast low paid dividend and SVM model executes worse than M&M model. As a result ANFIS model is observed the most successful method in forecasting dividends.

Keywords: Cash Dividend Forecasting, Marsh Merton Model, ANFIS, RBFN, MLP, SVM.

JEL Classification Codes: G35, C53, G17.

* Extended abstract is presented at the end of the article.

Atıfta bulunmak için...| Arsoy, M.F. & Güreşen, E. (2016). Nakit Temettü Tahmininde
Cite this paper...| Makine Öğrenmesi Yaklaşımı: İmalat Sektörü Üzerine Bir
Araştırma. *Çankırı Karatekin Üniversitesi İİBF Dergisi*, 6(1), 307-333.

1. Giriş

Finans literatüründe ‘temettü’ terimi, bir işletmenin elde ettiği toplam kârdan ortaklara dağıtılan kesin kâr miktarını belirtmektedir. Temettü politikası ise elde edilen kârın ortaklara dağıtılıp dağılmayacağı, dağıtılacaksa miktarının ve dağıtım şeklinin ne olacağına karar verilmesi ve işletmenin piyasa değerini en yüksek düzeye çıkaracak biçimde uzun vadede izlenecek temettü ödeme oranının belirlenmesi anlamına gelmektedir. Ortakların beklentilerini karşılamada, temettü dağıtım politikası önemli bir araçtır. İşletmenin ortaklarına ‘artık’ nakit akış tutarına eşit miktarda temettü dağıtmasıyla, yönetimin kaynakları boşa harcaması imkânı ve dolayısıyla temsil maliyetleri azaltılabilmektedir (Hansen, Kumar ve Shome, 1994). Diğer yandan temettüler işletmelerin cari ve gelecek performansına işaret ederek işletmenin geleceğine yönelik sinyal içermektedir (Bhattacharya, 1979; Miller ve Rock, 1985; Nissim ve Ziv, 2001). Bu sinyal özelliği yatırımcılar tarafından temettü dağıtan işletmelerin daha risksiz ve güvenilir olarak algılanmasına, dolayısıyla bu işletmelerin piyasa değerlerinin diğerlerine göre genellikle daha yüksek olmasına yol açmaktadır.

Temettünün diğer bir önemi de işletmelerin değerini belirleyen temel faktörlerden biri olmasıdır. Genel olarak finasta, işletme veya varlık değerlemesinde, iskonto edilmiş nakit akışları (İNA) yöntemi, göreceli değerlendirme yöntemi (benzer emsal şirketler ile şirket değerinin kıyaslanması) ve opsiyon fiyatlandırma modeli (OFM) gibi üç farklı yöntem kullanılmaktadır. Son iki yöntem özellikle nakit akışı diğer bir deyişle temettü bilgisinin eksik olması nedeniyle İNA’nın uygulanmadığı durumlarda kullanılmaktadır. İNA ise, arbitraj oluşturmeyen durumlar ile ve paranın zaman değeri prensibiyle uyumlu olması gibi teorik avantajlarının bulunması ve kolay uygulanması nedeniyle varlık değerlendirmesinde çok kullanılan bir yöntemdir. Temettü miktarının İNA yöntemi ile belirlenmesi, yatırım, finansman, birleşme ve ele geçirmeler gibi konularda kararlar alınırken ilgili işletmenin doğru değerlemesi açısından büyük önem taşımaktadır. Bu yöntemin işletme değeri fiyatlandırmasında kilit rol oynaması, dağıtılacak temettülerin diğer bir deyişle nakit akışlarının tam olarak öngörüsü, doğru değerlendirme için hayati öneme sahip olmaktadır (Kim vd., 2010).

Belirtilen teorik gerekçeler dışında, diğer gelişen ülkelere göre yüksek enflasyonist baskı altında olan ve ekonomisi yüksek kırılabilirliğe sahip Türkiye gibi gelişmekte olan sermaye piyasalarında, yatırımcıların riskten kaçınmak için düzenli ve yüksek oranda temettü dağıtan işletmelere yöneldiği görülmektedir. Literatürde kurumsal ve bireysel yatırımcıların Borsa İstanbul’da işlem gören işletmelerin temettü ödemelerini dikkatle takip ettiğini ve buna göre pozisyon aldığını destekleyen bir çok çalışma mevcuttur (Tatari, 1999; Boztosun, 2006; Barak ve Demireli, 2006; Bayazıtlı vd., 2007; Gürel, 2008; Kaba, 2009; Ünlü vd., 2009).

Herhangi bir hisseye ilgi duyulması için, nakit temettü dağıtımının yeterli bir neden olup olmadığını sorgulayan Bulmuş (2012), çalışmasında Borsa İstanbul yatırımcısının temettü refleksini incelemiştir. Bunun için son üç yıl temettü dağıtmış hisselerden olmak üzere BİST 30 içinde yer alan 6 ve BİST 100 içinde yer alan 10 hisseyi kapsayan iki ayrı temettü endeksi hesaplanan araştırmada, her iki temettü endeksinin BİST 30 ve BİST 100'e göre daha yüksek getiri sağladığı gözlenmiştir. Çalışma sonucunda yatırımcıların, düzenli nakit temettü dağıtan hisse senetlerine daha fazla ilgi gösterdiği ve araştırma öncesindeki beklentilerin aksine, bu hisseleri yılın tamamında satın almaya devam ettikleri tespit edilmiştir.

Halka açık işletmelerde temettü dağıtım duyurularının hisse senedi fiyatları üzerindeki etkisini ölçen Kaderli ve Başkaya (2014)'nin çalışmasında, bilinçli yatırımcılar tarafından yatırım yapılırken, işletmelerin temettü dağıtım politikasının ve bu konudaki istikrarlılığının göz önünde bulundurulduğu, ayrıca bu faktörlerin işletmelerin piyasa değerini maksimuma çıkarmada önemli bir rol oynadığı belirtilmektedir. Çalışma sonucunda nakit temettü dağıtımının yatırımcılar açısından pozitif bir etki yarattığı ve herhangi bir işletmenin temettü ödemesini arttıracığına dair duyurusunun işletmenin piyasa değeri üzerinde olumlu yönde etkili olduğu tespit edilmiştir. Benzer şekilde bir işletmenin temettü ödemesini azaltacağına dair duyurusunun ise işletmenin piyasa değeri üzerinde olumsuz yönde oldukça etkili olduğu tespit edilmiştir.

Literatürde finansal başarısızlık ve kredi değerlemesi konularında birçok çalışma yapılmış olmasına rağmen, reel ve finansal yatırım kararlarında büyük önem taşıyan temettülerin tahmini konusunda yeterli çalışma olmadığı görülmektedir. Bildiğimiz kadarıyla, Marsh ve Merton (M&M) (1987)'in modeli dışında dağıtılan temettü miktarını tahmin edebilen iyi bir teorik model bulunmamaktadır (Kim vd. 2010). Ayrıca işletme değerini etkileyen en önemli yönetsel kararlardan biri olan temettü politikasının tahmininde makine öğrenme yaklaşımlarını kullanmış Kim vd. (2010) ve Won vd. (2012)'den başka herhangi bir araştırmanın mevcut olmaması da bu araştırmanın yapılmasında bizi motive etmiştir.

Yukarıdaki bilgileri çıkış noktası alan bu çalışmada, Türkiye'de halka açık işletmeler tarafından dağıtılan temettülerin tahmininde M&M modelinin kullanılabilirliğinin test edilmesi ve makine öğrenme tekniklerini uygulayarak, M&M modelinden daha iyi bir model geliştirilmesi amaçlanmıştır. Günümüzde temettülerin işletmeler tarafından nakit, hisse senedi, hisse geri alımı ve hisse senedi bölünmesi gibi çeşitli yöntemlerle dağıtıldığı görülmektedir. Ancak son yıllarda yapılan uluslararası bir çok araştırmada temettülerin nakit ödenme trendinin piyasalarda sürekli arttığı ve temettü ödeme politikasının esas şekli olarak belirginleştiği görülmektedir (Fama ve Kenneth, 2001; Julio ve Ikenberry, 2004; DeAngelo vd., 2004; Brav vd., 2005). Dolayısıyla hem en çok kullanılan temettü dağıtım politikası olması, hem de İNA yöntemini firma değerlemesine

uygulamada genellikle temettü anlamına gelen gelecekte beklenen nakit akışlarına gerek duyulması nedeniyle bu çalışmada nakit temettü ödemesi yöntemine odaklanılmıştır. Çalışmanın amacını gerçekleştirmek için, hisse senetleri Borsa İstanbul'da işlem gören imalat sektöründeki işletmelerin verilerine M&M modeli uygulanmıştır. Ayrıca bu modelde kullanılan değişkenler kullanılarak farklı makine öğrenmesi teknikleri kullanılarak, nakit ödenen temettü oranlarını tahmin eden modeller elde edilmiştir. Tüm modellerin performansları ortalama hata kareleri (OHK) değerleri üzerinden karşılaştırılarak en başarılı tahmine sahip model belirlenmiştir.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir. İkinci bölümde literatürde temettü tahminine yönelik yapılmış deneysel çalışmalar ile uygulamada kullanılan makine öğrenmesi teknikleri özetlenmiştir. Uygulamada kullanılan modeller, veri toplama, örnekleme yöntemleri ve değişken seçimi üçüncü bölümde açıklanmıştır. Modellerin analizi ile elde edilen bulgular ise dördüncü bölümde yer almaktadır. Beşinci bölümde ulaşılan sonuçlar ortaya konulmuştur.

2. Literatür Özeti

2.1. Temettü Tahminine Yönelik Çalışmalar

Literatürde işletmeler tarafından dağıtılan temettü miktarının veya oranının açıklanması, genellikle Lintner (1956) modelinin esas alınmasıyla temettü davranış modeli şeklinde yapılmıştır. Yıllık finansal raporlara göre bir sonraki yıl içinde dağıtılacak temettünün, bir kısmının işletmenin cari yılda elde edilen kârına, bir kısmının ise cari yıl içinde dağıtılan önceki yıla ait temettüye bağımlı olduğunu gösteren Lintner (1956)'in modeli, temettü politikası konusunda önemli bir dönüm noktası teşkil etmektedir.

Marsh ve Merton (1987) ise tüm hisse senedi piyasasının temettü miktarını, işletmelerin sürekli kârlarındaki değişimin bir fonksiyonu olarak dinamik davranış modeli yardımıyla tahmin etmiştir. Sürekli kârlardaki değişimi ölçme amacıyla kurulan model, Lintner (1956), Brittain (1966), Fama ve Babiak (1968)'in bireysel işletme temettü davranış modellerini esas alarak oluşturulmasına rağmen, kâr yerine hisse senedi fiyatlarındaki değişimler kullanılmıştır. Çalışmada modelin performansı hem adı geçen kâra dayalı modeller ile hem de Shiller (1983)'in oto regresyonlu trend modeli ile karşılaştırılmıştır. Araştırmacılar çalışmalarında piyasadaki toplam temettünün sistematik bir zaman serisi davranışı gösterdiğini, bunun hisse senetleri fiyatlarında geciktirilmiş gerçek değişimlere neden olan toplam gerçek temettü değişimlerini içeren hata düzeltme modeli ile iyi tanımlandığını, hisse senedi fiyat modelinin, içinde cari ve geciktirilmiş kârların bulunduğu Lintner (1956) modelini kullanan Brittain (1966), Fama ve Babiak (1968) ve Watts (1973)'in daha önceki temettü modellerine eşit derecede performans gösterdiğini gözlemlemişlerdir. Ayrıca araştırmada sadece geciktirilmiş fiyatları kullanan hisse senedi modelinin gelecekteki temettü

değişimlerini tahmin etmede kullanılabileceği, sadece geciktirilmiş kârları kullanan modelin ise hisse senedi fiyat modelinden kötü performans gösterdiği sonucuna ulaşılmıştır.

Marsh ve Merton (1987)'in çalışmasından sonra yapay sinir ağları, makine öğrenmesi teknikleri ve genetik algoritma gibi genellikle mühendislik alanlarında kullanılan yöntemlerin son yıllarda temettü tahmini amacıyla kullanılmaya başlandığı görülmektedir. Pek çoğu doğrusal olmayan bu yöntemlerin tek başına veya birkaç yöntemin karışımı şeklinde ya da bazı kuralların ilave edilerek kullanıldığı ve geleneksel doğrusal yöntemlere göre daha başarılı tahmin sonuçları elde edildiği görülmektedir. Bununla birlikte temettü tahmininde yeni yaklaşımların kullanıldığı çok az çalışma (Kim vd., 2010; Salehi vd., 2012; Won vd., 2012) bulunmaktadır.

Kim vd. (2010), iskonto edilmiş nakit akışları ile bir işletmenin cari değerinin fiyatlamasında kilit rol oynayan, dağıtılacak temettülere odaklanmışlardır. Araştırmacıların işletme değerini fiyatlarırken başarılı bir modelin geliştirilmesine anlamlı katkı sağlayabilmek için, dağıtılacak temettülerin tahmininde M&M modelinden daha başarılı bir yöntem bulmayı amaçladığı görülmektedir. Makine öğrenmesi tekniklerinin uygulandığı araştırmada, 1980 ve 2000 yılları arasındaki dönemde Kore borsasına kote olmuş 685 işletme arasından, 15 yıldan fazla temettü kaydı olan ve eksik verisi bulunmayan 137 işletmenin verisi kullanılmıştır. Marsh ve Merton (1987)'in temettü tahmin modelinin geçerliliğinin Kore sermaye piyasalarında test edildiği araştırmada, modelin bu piyasalarda işletme bazında temettü tahmini için kullanılabileceğine yönelik güçlü bulgular elde edilmiştir. Çalışmada kayıp veri setinden bazı kuralların belirlenmesi ile oluşturulan “bilgi entegrasyonu” adı verilen modelin etkinliği, M&M modeli, yapay sinir ağları ile sınıflandırma ve regresyon ağacı yöntemleri ile karşılaştırılmıştır. Çalışma sonucunda mimarisi dengeli bir kurallar bütünü yaklaşımı olarak adlandırılan “bilgi entegrasyonu” modelinin, dört model arasında temettü tahmin doğruluğunda en başarılı model olduğu tespit edilmiştir.

Salehi vd. (2012) 2006 ve 2010 yılları arasındaki dönemde Tahran borsasında işlem gören petro-kimya sektöründeki 23 işletmenin oluşturduğu örnekleme, dağıtılan nakit temettü miktarının tahmininde etkin bileşenlerin ne olduğunu, yapay sinir ağları ve genetik algoritma kullanarak açıklamışlardır. Araştırmada sadece yapay sinir ağları ve yapay sinir ağlarıyla genetik algoritmanın birlikte kullanıldığı melez model olmak üzere iki model kullanılmıştır. Çalışma sonucunda genetik algoritmanın yapay sinir ağları ile birlikte kullanıldığı melez modelin, sadece yapay sinir ağlarına dayalı modele göre nakit temettü miktarını daha başarılı tahmin ettiği gözlenmiştir.

Makine öğrenme yaklaşımları ile temettü tahmini üzerinde çalışan Won vd. (2012), genetik algoritmadan yararlanarak veri setinden kuralla dayalı algoritmalar aracılığıyla elde edilen ve birçok kuralı oluşturup filtreleyebilen bir “bilgi rafine

modeli” geliştirmişlerdir. Araştırmada 1980 ve 2000 yılları arasındaki dönemde Kore borsasına kote olmuş 15 yıldan fazla temettü kaydı olan ve eksik verisi bulunmayan 137 işletmenin meydana getirdiği örnekleme, tahmin edici değişkenler olarak “cari dönem temettü, geçmiş dönem ve cari dönem hisse senedi fiyatları”, hedef değişkeni olarak “gelecekteki temettü politikası” kullanılmıştır. Araştırmacılar temettü tahmin doğruluğu için “Bilgi filtreleyen genetik algoritma” modeli ile CHAID, CART, QUEST ve C5.0 modellerini karşılaştırmışlardır. Çalışma sonucunda temettü politikası tahmininde “Bilgi rafine eden genetik algoritma” modelinin, diğer (CHAID, CART, QUEST, C5.0) modellerden her zaman daha başarılı performans gösterdiği, diğer bir deyişle daha doğru tahminde bulunduğu tespit edilmiştir.

2.2. Makine Öğrenmesi Yöntemleri

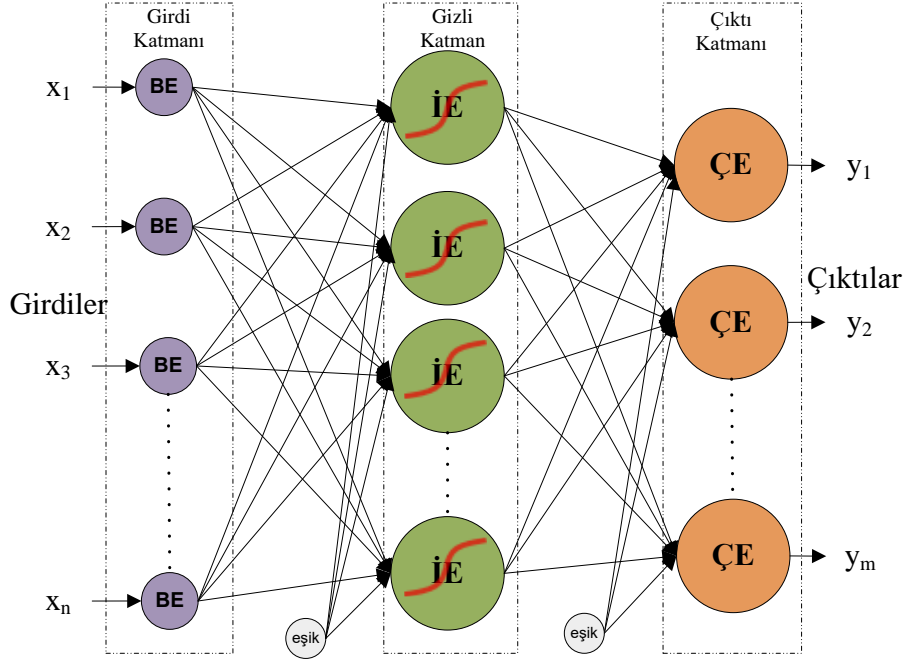
Makine öğrenme tekniklerinin, finans literatüründe finansal başarısızlık (Keskin, 2002; Çakır, 2005; Akkoç, 2007; Akkaya, Demireli ve Yakut, 2009; Çelik, 2010; Yakut, 2012), iflas öngörüsü vasıtasıyla kredi politikası kararları (Anandarajan, Lee ve Anandarajan, 2001; Atiya, 2001; Charalambous, Chartious ve Kaourou, 2000; Pendharkar, 2005) ve kredi değerlemesi (Chen ve Huang, 2003; Tsai ve Wu, 2008; Muzır, 2011) gibi finansal karar alma problemlerini çözmede kullanıldığı görülmektedir. Ancak temettü politikası işletme değerini etkileyen en önemli yönetsel kararlardan biri olmasına rağmen, bildiğimiz kadarıyla temettü politikası veya temettü tahmininde makine öğrenmesi yaklaşımlarının çok az sayıda araştırmada kullanıldığı (Kim vd., 2010; Salehi vd., 2012 ve Won vd., 2012) anlaşılmaktadır. Bu çalışmada kullanılan makine öğrenmesi yöntemleri aşağıda açıklanmıştır.

2.2.1. Çok Katmanlı Algılayıcılar (ÇKA)

Çok katmanlı algılayıcılar (Multi-Layer Perception) çok kullanılan ve günümüzde yapay sinir ağları (YSA) denildiğinde ilk akla gelen yapılardır. Frank Rosenblatt (1958) tarafından geliştirilen algılayıcının (perception) birden fazla katman olarak kullanılmasıyla çok katmanlı algılayıcılar ortaya çıkmıştır. Çok katmanlı algılayıcılar (ÇKA) girdi ve çıktı katmanları arasında en az bir gizli katman kullanan yapılardır. Bu yapılar girdi değerleri ile çıktı değerleri arasındaki doğrusal ilişkileri tespit edebildiği gibi doğrusal olmayan ilişkileri de tespit edebilmektedir. Temel olarak girdi katmanı, dış ortamdan gelen bilgileri alıp gizli katmana iletmeye rol alır. Bu bilgiler gizli katmanda işlenir ve değişim işleminden sonra bir sonraki katmana iletilir. Bir sonraki katman başka bir gizli katman olabileceği gibi çıktı katmanı da olabilir. Çıktı katmanı ise dış ortama sonuçlar / tepkiler üretir.

Çok katmanlı algılayıcılar için tek gizli katmanlı örnek Şekil 1’de verilmiştir. Burada BE’ler başlangıç elemanlarını, İE’ler işlem elemanlarını, ÇE’ler çıkış elemanlarını ve eşikler işe fonksiyonlarda kullanılan eşik değerini temsil

etmektedir. İşlem elemanlarının üzerindeki “s” şekilli çizgiler ise genelde kullanılan tanh(.) veya sigmoid(.) şeklindeki doğrusal olmayan transfer fonksiyonunu ifade etmektedir.



Şekil 1: Çok Katmanlı Algılayıcı Yapısı

ÇKA yapısının uygun parametrelerle sürekli çok değişkenli bir fonksiyonu modelleyebilmesinin ispatlanması bu alandaki çalışmaları hızlandırmıştır (Hornik vd., 1989, Funahashi, 1989, Hornik vd. 1990, Funahashi, 1990, Hornik, 1991, Hornik, 1993). Böylece yapay sinir ağları tarihinde önemli bir devreye girilmiş ve bir çok çalışmada ÇKA, farklı öğrenme algoritmalarının uygulanmasına imkan sağlaması nedeniyle tercih edilmiştir.

Çok katmanlı algılayıcılarda öğrenme algoritmalarına hata yayma modeli veya geriye yayılım algoritması örnek verilebilir. Genelde Delta kuralı olarak adlandırılan öğrenme kuralının yaygın olarak kullanılmasıyla birçok yeni öğrenme algoritması ÇKA yapısı üzerinde geliştirilmiştir. Delta kuralı, en küçük kareler yöntemi kullanarak, yapay sinir ağının hesapladığı çıktı değeri ile beklenen çıktı değeri arasındaki farkı azaltmaya dayanmaktadır.

2.2.2. Radyal Tabanlı Fonksiyon Ağları (RTFA)

Radyal Tabanlı Fonksiyon Ağları (RTFA) ilk olarak Broomhead ve Lowe (1988) tarafından geliştirilmiştir. Radyal Tabanlı Fonksiyon Ağlarının genel özellikleri şu şekilde sıralanabilir (Haykin, 2009);

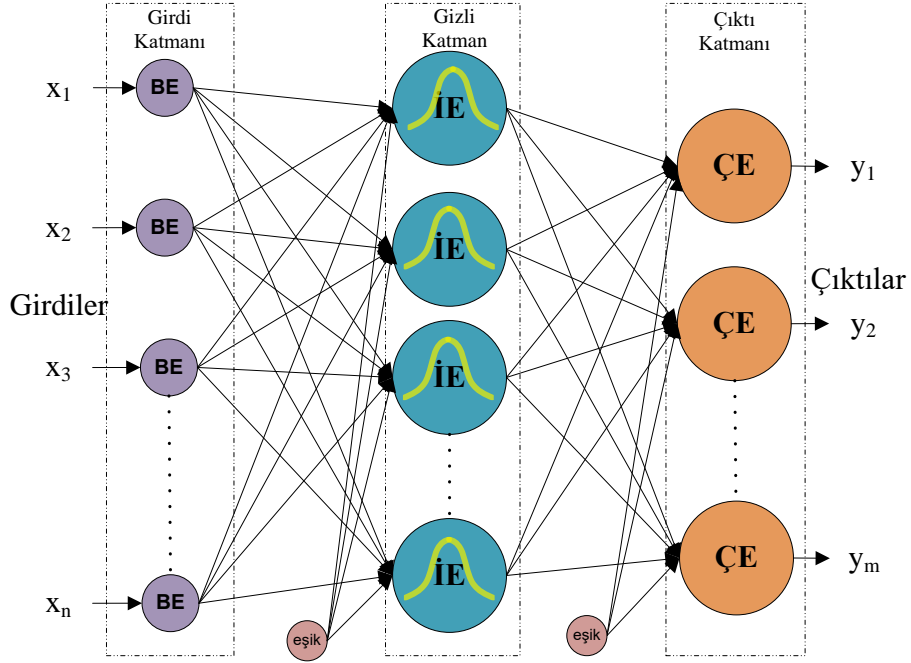
- Girdi, gizli ve çıktı katmanından oluşan ileri beslemeli bir ağdır.
- Gizli Katmandaki işlem elemanları radyal tabanlı fonksiyonları (Gaussian Fonksiyonu vb.) kullanır.
- Çıktı katmanındaki çıktı elemanları ise lineer fonksiyon kullanır.
- Ağın eğitimi iki temel aşamada olur.
 - Girdi ve gizli katman arasındaki ağırlıkların gözetimsiz eğitim ile (Kohonen, k-ortalama vb.) bulunması.
 - Gizli katman ile çıktı katmanı arasındaki ağırlıkların lineer olarak bulunması.

Kısaca RTFA bir $f(x)$ fonksiyonu Denklem 1 ile tahmin eder:

$$f(\mathbf{x}) = \sum_{i=1}^n w_i \phi(r_i) \quad (1)$$

Burada $r_i = \|x - c_i\|$ ve $x \in R^n$: girdi vektörü, c_i küme merkezi değer vektörü (girdi ile gizli katman arasındaki ağırlık), w_i gizli katman ile çıktı katmanı arasındaki ağırlık, $\phi(\cdot)$ transfer fonksiyonudur (radyal olarak simetrik).

Çok katmanlı algılayıcılara benzer şekilde radyal tabanlı fonksiyon ağırları yapısı Şekil 2'de gösterilmiştir. RTFA'lar bir gizli katmana sahip ÇKA'ya benzemektedir. Aralarındaki fark işlem elemanlarının ağırlıklı toplam yerine girdiler ile kendi ağırlıkları arasındaki mesafeyi kullanması ve bu mesafeyi radyal tabanlı transfer fonksiyonlarından geçirmesidir. İşlem elemanlarının üzerindeki çan eğrisi şeklindeki çizgiler ise genelde kullanılan radyal tabanlı transfer fonksiyonlarını ifade etmektedir.




Şekil 2: Radyal Tabanlı Fonksiyon Ağı Yapısı

2.2.3. Destek Vektör Makineleri (DVM)

Destek Vektör Makineleri (DVM) Boser, Guyon ve Vapnik tarafından 1992'de (Boser vd., 1992) geliştirilmiş ve 1990'lı yılların sonuna doğru araştırmacılar arasında yaygınlaşmıştır (Vapnik, 1998). DVM'leri günümüzde birçok sınıflama probleminde popüler hale gelmiştir. DVM yöntemleri, regresyon (Vladimir Vapnik vd., 1997) ve temel bileşen analizi (Schölkopf vd., 1999) gibi birçok problem türüne uygulanır hale gelmiştir.

DVM'leri özellik uzayını lineer olarak sınıfların temsil edildiği destek vektörlerini kullanarak bölmeye dayanır. Doğrusal olarak bölünemeyen özellik uzaylarını ise bir dönüşümler daha yüksek boyutlu uzaya taşıyarak lineer olarak ayrılabilir yapmaya dayanır. Bunun bir örneği Şekil 3'de görülmektedir.

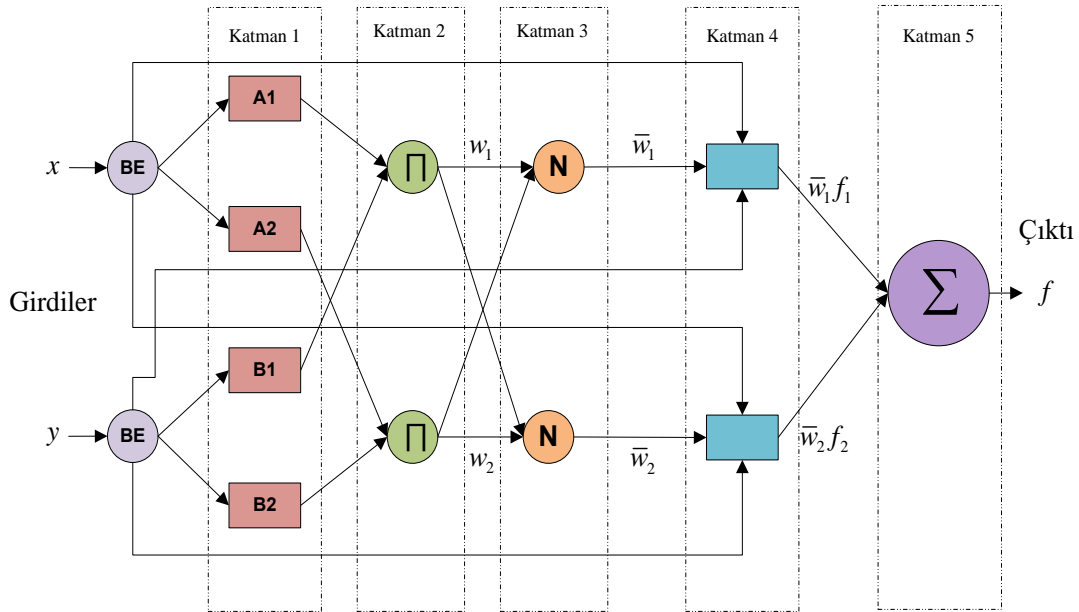
DVM için parametre seçimi için genel bir yöntem olmadığından deneme yanılma yolu veya meta-sezgisel yöntemler kullanılmaktadır.



Şekil 3: Destek Vektör Makineleri Çalışma Prensipli

2.2.4. Adaptif Sinirsel Bulanık Çıkarsama Sistemi (ASBÇS)

Adaptif sinirsel bulanık çıkarsama sistemleri (Adaptive Neuro-Fuzzy Inference Systems; ANFIS) Jang (1993) tarafından geliştirilmiştir. ASBÇS doğrusal olmayan herhangi bir fonksiyonun genel modelleyicisi olarak kullanılabilir (Aytek, 2009). ASBÇS yapısının dayandığı nokta yapay sinir ağları ile bulanık çıkarsama sistemlerinin avantajlarının tek bir modelde birleştirilmesidir. ASBÇS yapısı genel olarak Şekil 4’de görüldüğü gibidir.



Şekil 4: ASBÇS Yapısı.

Kaynak: Dinh ve Afzulpurkar (2007)

ASBÇS yapısı girdilere üyelik fonksiyonu uygulayan bulanık işlem elemanları içerir. Üyelik fonksiyonu için genellikle çan şeklindeki fonksiyonlar veya Gaussian seçilir (Principe vd., 2000).

Şekil 4’de genel yapısı görülen ASBÇS için her l katmanındaki i ’nci düğümün çıktısı $O_{l,i}$ şeklinde gösterilmek üzere (Dinh ve Afzulpurkar, 2007);

Katman 1; Adaptif düğümleri içerir,

$$O_{l,i} = \mu_{A_i}(x) \quad i = 1, 2 \quad (2)$$

$$O_{l,i} = \mu_{B_{i-2}}(y) \quad i = 3, 4 \quad (3)$$

burada $\mu_{A_i}(x)$ ve $\mu_{B_{i-2}}(y)$ uygun üyelik fonksiyonlarıdır. $O_{l,i}$ ise bulanık küme $A(= A_1, A_2, B_1$ veya $B_2)$ ’ya olan üyelik derecesini ve girdi $x(y)$ ’in A ’yı gerçekleştirme derecesini göstermektedir.

Katman 2; Π ile işaretlenmiş olan düğümlerin çıktısı ise gelen tüm sinyallerin çarpımıdır;

$$O_{2,i} = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad (4)$$

Böylece her bir düğümün çıktısı bulanık kontrol kuralının sinyal gücünü temsil eder.

Katman 3; N ile işaretlenmiş düğümler ise aşağıda verilen denklemlerle normalize edilmiş sinyaller üretirler;

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (5)$$

Katman 4; Adaptif düğümleri içerir ve çıktısı aşağıdaki gibidir;

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (6)$$

Katman 5; Toplama yapan tek bir Σ işaretli düğüm ile ağın sonucunu üretir;

$$\text{Ağın Çıktısı} = O_{5,1} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (7)$$

3. Yöntem

Marsh ve Merton (1987)'in, genel denge çerçevesini uygulayarak diğer modellere göre oldukça iyi performans gösteren bir temettü tahmin modeli geliştirmeyi başardığı görülmektedir. Bir sonraki dönem içinde dağıtılacak temettü miktarını tahmin etmek için, sadece cari dönem ve geçmiş döneme ait hisse senedi fiyatları ile temettü miktarları kullanılan modelde, defter değerlerinin yerine piyasa değerleri ele alınmıştır. Dolayısıyla bu çalışmada temettü tahmini için, M&M modelinin çatısı uygulanarak, geçmiş ve cari dönem hisse senedi fiyatları ile geçmiş dönem temettü dağıtım oranları, dağıtılacak nakit temettülerin esas belirleyici faktörleri olarak kullanılmıştır (Bkz. Tablo 1).

Marsh ve Merton (1987), dağıtılacak temettüleri tahmin etmek için, orijinal denge modelinden aşağıdaki yapısal regresyon modelini türetmiştir (Denklem 8).

$$\ln\left(\frac{D_{t+1}}{D_t} + \frac{D_t}{P_{t-1}}\right) = a_0 + a_1 \ln\left(\frac{P_t + D_t}{P_{t-1}}\right) + a_2 \ln\left(\frac{D_t}{P_{t-1}}\right) + \varepsilon_{t+1} \quad (8)$$

D_t ve P_t sırasıyla t periyodundaki temettü ile hisse senedi fiyatı, ε_{t+1} ; $t+1$ periyodundaki hata terimi ve \ln ise doğal logaritmayı ifade etmektedir. Regresyon parametrelerini, a_0, a_1 ve a_2 olarak saptadıktan ve D_{t+1} için denklemi tekrar düzenledikten sonra, geçmiş döneme ait cari dönem içinde dağıtılan temettü D_t , geçmiş dönem hisse senedi fiyatı P_{t-1} ve cari dönem hisse senedi fiyatı P_t değişkenlerini kullanarak, cari döneme ait bir sonraki dönemde dağıtılması beklenen temettüyü, D_{t+1} , Denklem 1'den elde edebiliriz. Diğer bir deyişle tahmin edilmiş temettü aşağıdaki denklemi kullanarak elde edilebilir. Dolayısıyla Denklem 9, bu çalışmada kıyaslama modeli olarak kullanılacak olan M&M modelidir.

$$D_{t+1}^{\text{Öngörülen}} = D_t \left[e^{a_0} \times \left(\frac{P_t + D_t}{P_{t-1}}\right)^{a_1} \times \left(\frac{D_t}{P_{t-1}}\right)^{a_2} - \frac{D_t}{P_{t-1}} \right] \quad (9)$$

Çalışmada cari döneme ait bir sonraki dönemde dağıtılan temettü oranını en iyi tahmin eden modele ulaşmak için, Denklem 9'daki M&M modeli ile ÇKA (Bir Gizli Katman), ÇKA (İki Gizli Katman), RTFA, DVM ve ASBÇS şeklinde farklı makine öğrenme teknikleriyle geliştirilen toplam altı model kıyaslanmıştır. Makine öğrenmesi yöntemlerinde P_t , P_{t-1} , D_t ve D_{t+1} değişkenleri M&M modelinin aksine, birbirleriyle toplama veya birbirlerinin oranlarını alma gibi değişken dönüşümü işlemleri uygulanmadan doğrudan kullanılmıştır. M&M modelinin parametreleri en küçük kareler yöntemi ile Microsoft Excel 2010 programında hesaplanmıştır. ÇKA, RTFA ve DVM modelleri için SPSS

Clementine 12 (yeni adı IBM Modeller) yazılımı, ASBÇS modeli ise NeuroSolutions v5.06 yazılımı kullanılarak oluşturulmuştur.

4. Veri Seti ve Bulgular

Bu araştırmanın çalışma evrenini, hisse senetleri Borsa İstanbul'da işlem gören ve temettü dağıtan işletmeler oluşturmaktadır. Ancak mali kuruluşlar ile ticaret ve hizmet işletmeleri farklı özellikler taşıdığı için bu veri kümesinden çıkarılmıştır. Geriye kalan ve temettü dağıtımının yaygın olduğu BİST imalat sektöründeki işletmelerden oluşan veri seti, örneklem olarak kullanılmıştır. Türkiye ekonomisinde 1990'lı yıllardaki krizlere göre daha istikrarlı ve kesintisiz bir gelişmenin yaşandığı 2003-2012 yıllarını kapsayan 10 yıllık süre, araştırma dönemi olarak belirlenmiştir.

Çalışmada 2003-2012 yılları arasında hisse senetleri Borsa İstanbul'da işlem gören imalat sektöründen 168 işletmeye ait yıllık veriler, Kamuyu Aydınlatma Platformunun (KAP) "<http://www.kap.gov.tr/>" elektronik veri tabanından ve Finnet Elektronik Yayıncılık Data Limited Şirketinin "<http://www.finnet.gen.tr/>" kurumsal web sitesinden elde edilmiştir.

Tablo 1: Bağımlı ve Bağımsız Değişkenler

Değişken Tipi	Gösterim	Değişken adı	Açıklama
Bağımsız	P_t	Cari (t) Dönem Hisse Senedi Kapanış Bölünmemiş Fiyatı	Hisse senedinin cari yılın (t) en son iş günü Borsa İstanbul'daki kapanış bölünmemiş fiyatı
	P_{t-1}	Bir Önceki (t-1) Dönem Hisse Senedi Kapanış Bölünmemiş Fiyatı	Hisse senedinin bir önceki yılın (t-1) en son iş günü Borsa İstanbul'daki kapanış bölünmemiş fiyatı
	D_t	Bir Önceki (t-1) Döneme Ait Cari (t) Dönem İçinde Nakit Ödenen Brüt Temettü Oranı (%)	Bir önceki yılın(t-1) bilanço verilerine göre cari yıl(t) içinde ödenen nakit brüt temettü miktarı / Bir önceki yıla(t-1) ait vergi sonrası net kâr
Bağımlı	D_{t+1}	Cari (t) Döneme Ait Bir Sonraki (t+1) Dönem İçinde Nakit Ödenen Brüt Temettü Oranı (%)	Cari yılın(t) bilanço verilerine göre bir sonraki yıl(t+1) içinde ödenen nakit brüt temettü miktarı / Cari yıla(t) ait vergi sonrası net kâr

Bazı işletmelerin her yıl temettü dağıtmaması, bazılarının ise 2003 yılından sonraki yıllarda halka açılarak temettü dağıtmış olması nedeniyle, her yıl temettü dağıtan işletme sayısı değişkenlik göstermektedir. Üst üste iki yıl temettü dağıtmayan, birleşen veya bölünen, iflas eden, kotasyondan çıkarılan işletmelere ait gözlemler eksik veri nedeniyle örneklemden çıkarılmıştır. Dolayısıyla, Denklem 9'daki regresyon parametrelerini tahmin etmek için, çalışma örneklemini olarak 2003-2012 yılları arasında en az 2 yıl üst üste nakit temettü dağıtan toplam 139 şirkete ait 420 adet gözlem değeri kullanılmıştır. Örnekleme oluşturan bu gözlemlerden rassal olarak seçilen %80'i (336/420) eğitimde yani model parametrelerinin tespitinde, %20'si (84/420) ise modellerin performansının ölçülmesinde kullanılmıştır. Araştırmada kullanılan bağımlı ve bağımsız değişkenler Tablo 1'de gösterilmiştir.

Oluşturulan modellerin performansını ölçmek için, elde edilen sonuçların gerçek değere ne kadar yakınlık gösterdiğini ifade eden ortalama hata kareleri (OHK) kullanılmıştır. Ortalama Hata Kareleri (OHK) aşağıda belirtilen Denklem 10 ile hesaplanmıştır:

$$OHK = \frac{1}{n} \times \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (10)$$

burada y_i gerçekleşen temettü değerlerini gösterirken \hat{y}_i ise modelin tahmin ettiği temettüyü göstermektedir.

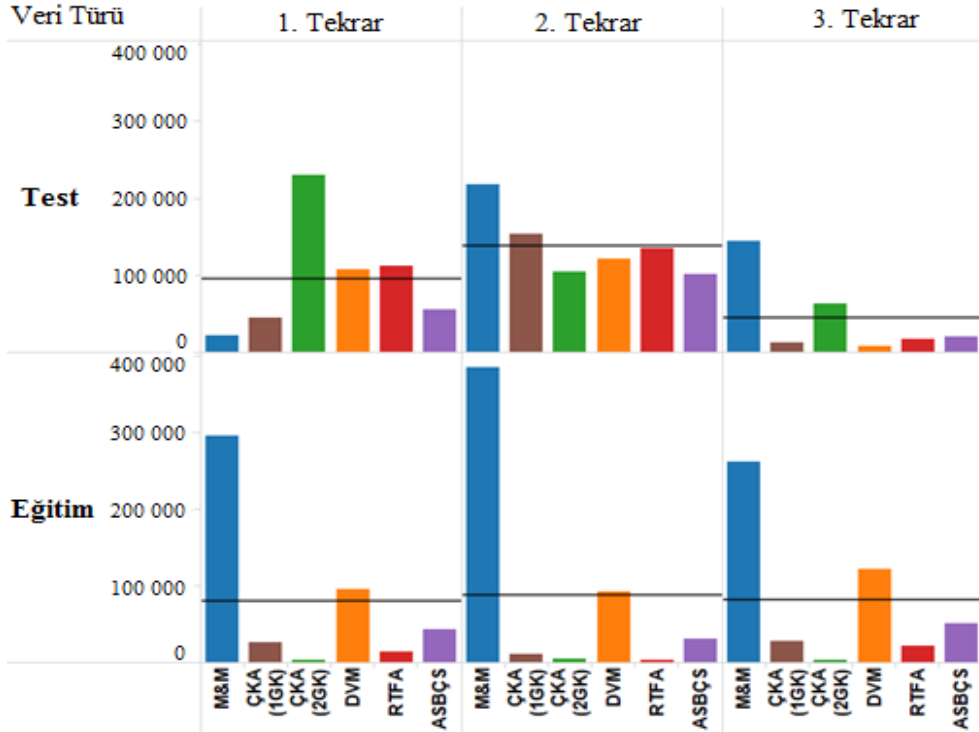
Çalışmada sonuçların genelleştirilebilmesi bakımından, 420 adet gözlem değerinden oluşan örneklem içinden eğitim ve test kümelerinin rassal olarak seçilmesi ve performans ölçümü işlemi üç kez yinelenmiştir. Test kümesinin her seferinde rassal olarak tamamen değişmesi sağlanarak bulgular karşılaştırılmıştır. 3 tekrar için M&M, ÇKA (Bir Gizli Katman), ÇKA (İki Gizli Katman), RTFA, DVM ve ASBÇS modellerinin eğitim ve test kümelerine ait OHK değerleri Tablo 2'de ve Şekil 5'de görülmektedir. OHK değerlerinin ortalaması Tablo 2'de en sağ sütunda, Şekil 5'de ise her tekrar için çizgi ile gösterilmiştir.

Tablo 2 ve Şekil 5 birlikte incelendiğinde eğitim aşamasında en yüksek hata değerlerini veren M&M modelinin, test kümesinde de bir deneme dışında en yüksek OHK değerlerine ulaştığı görülmektedir. Test verisinde 58482 OHK değeri ile en düşük ortalama hataya ASBÇS modeli sahip olurken, ikinci en düşük ortalama hataya 69799 OHK değeri ile ÇKA (Bir Gizli Katman) modeli ulaşmıştır. En yüksek ortalama hataya 132627.40 OHK değeri ile ÇKA (İki Gizli Katman) modeli, ikinci en yüksek ortalama hataya ise 127809 OHK değeri ile M&M modeli sahip olmuştur. Test kümesinde her tekrarda ortalama daha yüksek hata performansına sahip modeller değişmiş, ancak ASBÇS modeli her seferinde ortalama daha az hata düzeyine sahip olmuştur. Böylece ASBÇS

modeli, hem 3 tekrarda ortalamadan daha iyi performans göstererek hem de en düşük OHK ortalamasına ulaşarak diğer modellerden net bir şekilde ayrılmıştır.

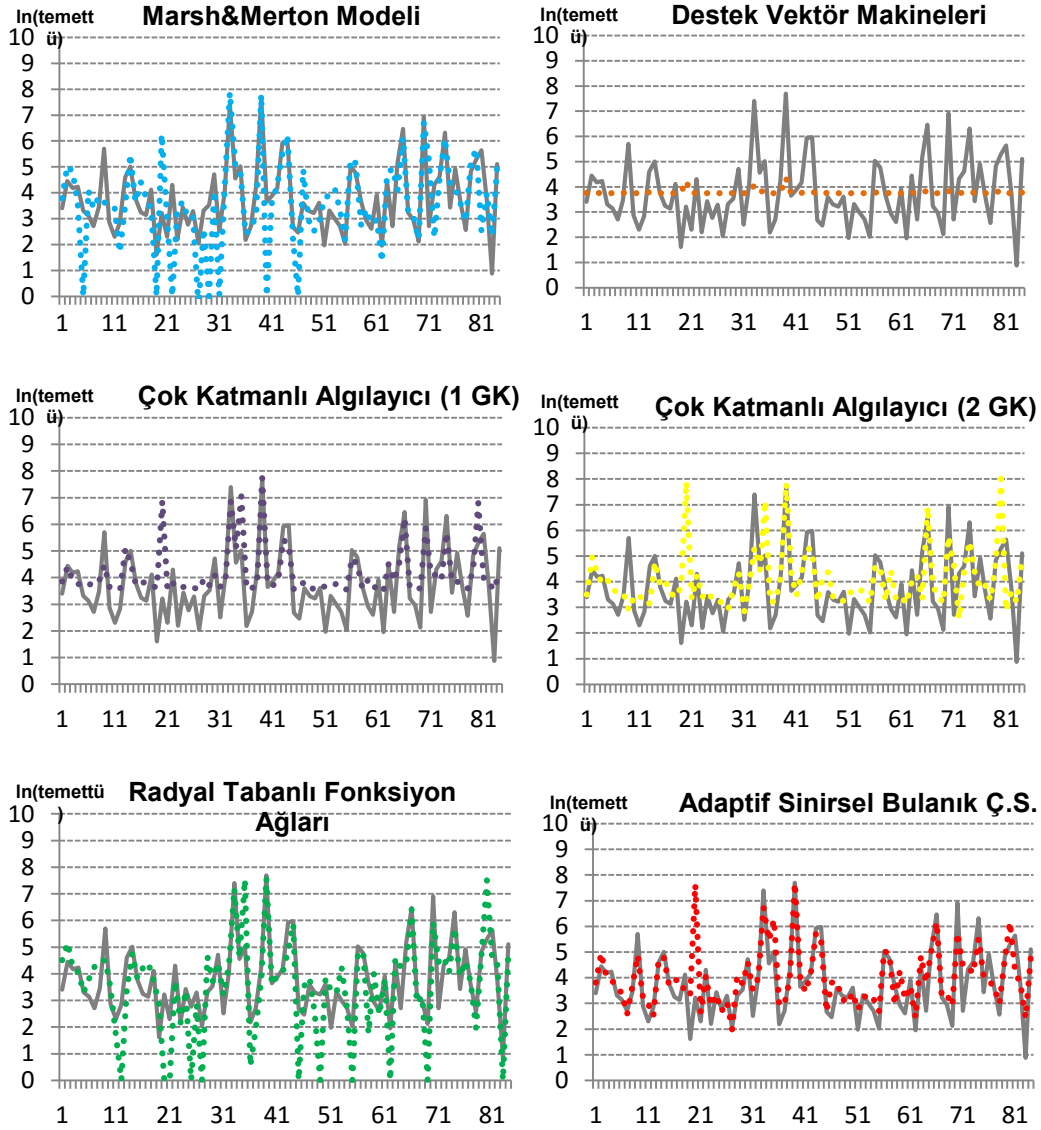
Tablo 2: Modellerin Eğitim, Test ve Ortalama OHK Değerleri.

Model	Veri Türü	Tekrar			Ortalama
		1	2	3	
M&M	Eğitim	296011.78	385346.20	261455.20	314271.06
	Test	21171.97	217661.53	144593.51	127809.00
ÇKA (1GK)	Eğitim	26411.09	10752.29	28030.50	21731.29
	Test	43692.97	153301.63	12402.55	69799.05
ÇKA (2GK)	Eğitim	3680.32	4705.92	3832.60	4072.95
	Test	229969.41	104756.90	63155.88	132627.40
DVM	Eğitim	95314.10	92422.10	120773.78	102836.66
	Test	107890.09	120393.47	8283.37	78855.65
RTFA	Eğitim	13686.06	3485.09	21379.46	12850.20
	Test	111229.46	135375.30	16494.68	87699.82
ASBÇS	Eğitim	43500.02	30807.09	51117.03	41808.04
	Test	54616.74	100529.63	20299.61	58481.99



Şekil 5: Modellerin Eğitim, Test ve Ortalama OHK Değerleri

Birinci tekrar için test kümesinde gerçekleşen ve modeller tarafından tahmin edilen “Cari (T) Döneme Ait Bir Sonraki (T+1) Dönem İçinde Nakit Ödenen Brüt Temettü Oran”larının doğal logaritmaları Şekil 6’da ayrı ayrı sunulmuştur. İkinci ve üçüncü tekrar için test kümesinde modellerin birinci tekrara benzer sonuçlar ürettiği görülmüştür.



Şekil 6: Birinci Tekrarda Gerçekleşen ve Tahmin Edilen Temettülerin Karşılaştırılması

Şekil 6’da M&M modeli ile gerçekleşen temettü oranı incelendiğinde, M&M ve RTFA modellerinin testlerde bazı noktalarda çok yakın değerler üretmekle birlikte, bazı noktalarda çok farklı değerler ürettikleri ve hatta zaman zaman sıfıra

yaklaşarak temettü veren firmaları hiç temettü vermeyecekmiş yada olduğundan çok daha düşük temettü verecek gibi tahmin ettikleri görülmektedir. DVM modelinin aslında eğitimi tam anlamıyla gerçekleştirmediği ve dar bir aralıkta sabite yakın değerler ürettiği gözlenmiştir.

Tek gizli katmanlı ve iki gizli katmanlı ÇKA modeller temettü oranlarını sürekli olarak belli bir değer üzerinde tahmin etmişler ve düşük miktardaki temettüleri tahmin etmede yeterli performansı gösterememişlerdir. ASBÇS modeli ise grafik olarak gerçekleşen temettüye en yakın tahmin değerlerini üretmiştir.

Çalışmada elde edilen sonuçların sağlamlığı farklı kontrol değişkenlerinin de analizlere dahil edilmesi ile test edilmiştir. Kontrol değişkenlerinin seçiminde Arsoy (2015)'un Türkiye'de halka açık işletmelerin temettü ödemesini etkileyen faktörlere ilişkin çalışmasından yararlanılmıştır. Literatürde temettü dağıtımı ile anlamlı ilişkisi olduğu tespit edilen ve işletmelerin kontrol edebildiği 43 değişkenin kullanıldığı çalışma sonucunda, "Hisse Senedi Fiyatı (P_t)", "Özsermaye Kârlılık Oranı (ÖKO)", "Hazır Değer Oranı (HDO)" ve "Net Satışlar (NS)"ın diğer bir deyişle istikrar, kârlılık, likidite ve büyüklük faktörlerinin, Borsa İstanbul'a kote olmuş işletmelerin dağıtacağı temettü miktarlarını belirleyen en önemli değişkenler olduğu tespit edilmiştir. İstikrarı temsil eden fiyat değişkeni M&M modeli içinde ve dolayısıyla çalışmadaki tüm modellerde yer aldığı için, diğer 3 değişken kontrol değişkeni olarak kullanılmıştır.

Bu nedenle örneklemdaki firmalar önce, kârlılık göstergesi olarak özsermaye kârlılığı, likidite göstergesi olarak hazır değer oranı ve büyüklük göstergesi olarak net satış değerlerine göre küçükten büyüğe göre sıralanıp küçük-büyük şeklinde iki gruba ayrılmıştır. Daha sonra en tutarlı ve en düşük ortalama OHK değerlerini veren ASBÇS modeli ile tüm örnekleme yapılan analizler, 3 farklı kontrol değişkenine ait 6 farklı alt örneklem üzerinde her defasında rassal olarak seçilen test kümesinde 3 kez tekrarlanmıştır. 3 kontrol değişkeni için 2 kümede (küçük-büyük) 3 tekrar olmak üzere ASBÇS modelinin toplam 18 kez uygulanması ile elde edilen OHK değerleri Tablo 3'de görülmektedir. Örneklemin kontrol değişkenleri bazında gruplanmasıyla oluşan alt veri kümelerinin açıklayıcı istatistikleri ve bağımsız değişkenler ile bağımlı değişken arasındaki korelasyonları ise Tablo 4'de verilmiştir.

Tablo 3'de özsermaye kârlılık oranı kontrol değişkeni için, özsermaye kârlılığı yüksek olan firmaların ortalama hatalarının, özsermaye kârlılığı düşük olan firmalardan daha düşük olduğu görülmektedir. Tablo 4'de ise özsermaye kârlılığı yüksek olan kümede bağımlı değişken ile bağımsız değişkenler arasındaki korelasyonların, özsermaye kârlılığı düşük olan kümeden daha yüksek olduğu, ayrıca bağımlı değişkenin, özsermaye kârlılığı büyük olan firma kümesi için daha düşük standart sapmaya ve daha dar aralığa sahip olduğu görülmektedir.

Tablo 3: Farklı Kontrol Değişkenlerine Göre ASBÇS Modelinin Test ve Ortalama OHK Değerleri.

Veri Türü	Kontrol Değişkeni		Tekrar			Ortalama
			1	2	3	
Test	ÖKO	Küçük	89053.81	188237.17	6990.72	94760.57
		Büyük	22895.91	1901.88	33004.75	19267.51
	HDO	Küçük	2765.55	676.74	2902.80	2115.03
		Büyük	91244.85	216531.22	26477.16	111417.74
	NS	Küçük	73372.42	209842.97	30752.17	104655.85
		Büyük	2929.77	911.54	1016.38	1619.23

Tablo 4. Farklı Örneklem Türüne Göre Korelasyon ve Tanımlayıcı İstatistikler.

Örneklem Türü	Bağımlı Değişken (d_t) ile Korelasyon			Bağımlı Değişken (d_t) İstatistikleri			
	p_t	p_{t-1}	d_{t-1}	Ortalama	Standart Sapma	Minimum	Maksimum
Tüm	0.687	0.611	0.618	119.37	307.07	1	3129.21
ÖKO Küçük	0.598	0.526	0.600	121.98	343.81	1	3129.21
ÖKO Büyük	0.844	0.775	0.648	116.75	266.10	1.12	3020
HDO Küçük	0.882	0.689	0.736	68.93	120.62	1	895
HDO Büyük	0.684	0.608	0.598	169.80	411.55	1.12	3129.21
NS Küçük	0.690	0.614	0.598	156.19	411.65	1	3129.21
NS Büyük	0.863	0.717	0.788	81.84	123.80	1.12	895

Hazır değer oranı kontrol değişkeni için, Tablo 3’de hazır değer oranı küçük olan firmaların ortalama hatalarının hazır değer oranı büyük olan firmalardan daha düşük olduğu görülmektedir. Tablo 4’de hazır değer oranının düşük olduğu kümede bağımlı değişken ile bağımsız değişkenlerin korelasyonlarının daha yüksek olduğu, ayrıca bağımlı değişkenin hazır değer oranı küçük olan firmaların oluşturduğu örneklem için daha düşük standart sapmaya ve daha dar bir aralığa sahip olduğu görülmektedir.

Net satışlar kontrol değişkeni için, net satış tutarları yüksek olan firmaların ortalama hatalarının, net satış tutarları düşük olan firmalardan daha düşük olduğu

Tablo 3’de görülmektedir. Tablo 4’de net satış tutarları yüksek olan kümede bağımlı değişken ile bağımsız değişkenlerin korelasyonlarının daha yüksek olduğu ve bağımlı değişkenin net satış tutarları yüksek olan firmaların oluşturduğu örneklem için daha düşük standart sapmaya ve daha dar bir aralığa sahip olduğu görülmektedir.

Tablo 3 ve Tablo 4 birlikte değerlendirildiğinde, özsermaye kârlılığı, hazır değer oranı ve net satışlar kontrol değişkenleri için, ASBÇS modelinin bağımlı değişken ile bağımsız değişkenler arasında yüksek korelasyon olan, aynı zamanda bağımlı değişkenin daha düşük standart sapmaya ve daha dar bir aralığa sahip olduğu alt örneklemelerde daha düşük ortalama OHK değerleri ürettiği görülmektedir.

5. Sonuç

Hisse senedi piyasasında istikrarlı getiri bekleyen, orta ve uzun vadede yatırım yapan yatırımcılar tarafından özellikle makroekonomik ve jeopolitik problemlerin olduğu dönemlerde, dağıtılan temettü miktarlarının yakından takip edildiği bilinmektedir. Bunun yanı sıra İNA yöntemi ile yapılan şirket değerlemesinde de, gelecekte dağıtılacak nakit temettü miktarları kullanılmaktadır. Bu nedenle işletmeler tarafından dağıtılan nakit temettü miktarının doğru tahmini, hem hisse senedi yatırımı açısından hem de finansal değerlendirme bakımından önem arz etmektedir.

Araştırmada Türkiye’de imalat sektöründeki halka açık işletmeler tarafından dağıtılan temettülerin tahmininde, M&M modeli ve makine öğrenmesi yöntemleri test edilmiş ve kullanılabilirlik düzeyleri ortaya konmuştur. Bunun için M&M modeli temel alınmış, bu modeldeki değişkenler kullanılarak RTFA, ÇKA, DVM ve ASBÇS gibi makine öğrenmesi yöntemlerinin gerçekleşen temettüleri tahmin etme performansı incelenmiştir. Böylece M&M’den daha iyi temettü tahmin modelleri araştırılarak teoriye ve hisse senedi yatırım kararlarına katkı sağlanmaya çalışılmıştır.

Çalışmada M&M ve RTFA modellerinin arasına gerçekleşen temettüye çok yakın değerler üretmekle birlikte, çoğu zaman çok farklı değerler ürettikleri ve hatta zaman zaman sifıra yaklaşarak temettü veren firmaları hiç temettü vermeyecek yada olduğundan çok daha düşük temettü verecek gibi tahmin ettikleri görülmektedir. DVM modelinin ise sabite yakın değerler üretmek suretiyle gerçekleşen temettüleri tahmin edemediği gözlenmiştir. Yüksek miktarda gerçekleşen temettü değerlerini tahmin edebilen tek gizli katmanlı ve iki gizli katmanlı ÇKA modellerinin, düşük miktardaki temettüleri tahmin etmede aynı performansı gösteremediği tespit edilmiştir. ASBÇS modelinin ise hem her tekrarda ortalamadan daha az hata ürettiği hem de en düşük OHK ortalamasına sahip olduğu için diğer modellerden net bir şekilde ayrıştığı görülmüştür

Sonuç olarak ASBÇS modelinin temettü tahmininde, M&M ve makine öğrenmesi modellerinden daha üstün performans sergilediği tespit edilmiştir. Dolayısıyla ASBÇS modelinin Borsa İstanbul'da temettü dağıtımına göre yatırım yapmayı tercih eden kurumsal ve bireysel yatırımcılar tarafından temettü tahmin modeli olarak kullanılabilirliği değerlendirilmektedir.

Bu çalışmanın sonuçlarını genelleştirmek için, kullanılan yöntemlerin gelişmekte olan diğer piyasalarda da test edilmesi yararlı olacaktır. İleride yapılacak araştırmalarda, araştırma modellerine işletme dışı değişkenlerin ve/veya CHAID, CART, QUEST ve C5.0 gibi farklı makine öğrenme yöntemlerinin entegre edilebileceği değerlendirilmektedir.

Kaynakça

- Akkaya, G.C., Demireli, E. ve Yakut, U.H. (2009). İşletmelerde Finansal Başarısızlık Tahminlemesi: Yapay Sinir Ağları Modeli ile İMKB Üzerine Bir Uygulama. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 10(2), 187-216.
- Akkoç, S. (2007). *Finansal Başarısızlığın Öngörülmesinde Sinirsel Bulanık Ağ Modelinin Kullanımı ve Ampirik Bir Çalışma*. Yayınlanmamış Doktora Tezi, Kütahya: Dumlupınar Üniversitesi Sosyal Bilimler Enstitüsü.
- Anandarajan, M., Lee, P. ve Anandarajan, A. (2001). Bankruptcy Prediction Of Financially Stressed Firms: An Examination Of The Predictive Accuracy Of Artificially Neural Networks. *International Journal of Intelligent Systems in Accounting, Finance and Management*, 10(2), 69-81.
- Arsoy, M.F. (2015). *İşletmelerde Dağıtılan Temettülerin Yapay Sinir Ağları ile Tahmini: Borsa İstanbul Sanayi Sektörü Üzerine Bir Uygulama*. Yayınlanmamış Doktora Tezi, Eskişehir: Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Enstitüsü.
- Atiya, A. (2001). Bankruptcy Prediction For Credit Risk Using Neural Networks: A Survey And New Results. *IEEE Transactions on Neural Networks*, 12(4), 929-935.
- Aytek, A. (2009). Co-Active Neurofuzzy İference System For Evapotranspiration Modeling. *Soft Computing*, 13, 691-700.
- Barak, O. ve Demireli, E. (2006). İMKB'de Gözlenen Fiyat Anomalilerinin Davranışsal Finans Modelleri Kapsamında Değerlendirilmesi. *10. Ulusal Finans Sempozyumu*, 01-03 Kasım 2006, Kuşadası-Aydın.

- Bayazıtlı, E., Kaderli, Y. ve Gürel, E. (2006). Kar Payı Dağıtma Duyurularının Firmaların Hisse Senedi Getirilerine Etkisi: İMKB'ye Kayıtlı Taş ve Toprağa Dayalı Sanayide Faaliyet Gosteren Bazı Firmalar Üzerinde Bir Olay Etüdü Çalışması, *Muhasebe ve Denetime Bakış Dergisi*, 26, 1-16.
- Bhattacharya, S. (1979). Imperfect Information, Dividend Policy, And 'The Bird In The Hand' Fallacy. *Bell Journal of Economics*, 10(1), 259-270.
- Boser, B.E., Guyon, I.M. ve Vapnik, V.N. (1992). A Training Algorithm For Optimal Margin Classifiers in USA. *The Fifth Annual Workshop On Computational Learning Theory. COLT92*, 144-152.
- Boztosun, D. (2006). *Temettü Dağıtma Kararının Farklı Piyasalarda Hisse Senedi Fiyatına Etkisinin Mukayeseli Olarak İncelenmesi*, Yayınlanmamış Doktora Tezi, Ankara: Gazi Üniversitesi Sosyal Bilimler Enstitüsü.
- Brav, A., Graham, J., Harvey, C. ve Michaely, R. (2005). Payout Policy İn The 21st Century. *Journal of Financial Economics*, 77, 483-527.
- Brennan, M.J. (1970). Taxes, Market Valuation and Corporate Financial Policy. *National Tax Journal*, 23, 417-442.
- Brittain, J.A. (1966). *Corporate Dividend Policy*. Brookings, Washington, D.C.
- Broomhead, D.S. ve Lowe, D. (1988). Multivariate Functional İnterpolation and Adaptive Networks. *Complex Systems*, 2, 321-355.
- Bulmuş, İ. (2012). Türkiye Borsa Yatırımcısının Temettü Refleksi. *Ekonomik Yaklaşım*, 23, 1-12.
- Charalambous, C., Chartious, A. ve Kaourou, F. (2000). Comparative Analysis Of Artificial Neural Network Models: Application İn Bankruptcy Prediction. *Annals of Operations Research*, 99, 403-425.
- Chen, M.C. ve Huang, S.H. (2003). Credit Scoring And Rejected İnstances Reassigning Through Evolutionary Computation Techniques. *Expert Systems with Applications*, 24(4), 433-441.
- Cybenko, G. (1989). Approximation By Superpositions of A Sigmoidal Function. *Math. Control Signals Systems*, 2, 303-314.
- Çakır, M. (2005). *Firma Başarısızlığının Dinamiklerinin Belirlenmesinde Makina Öğrenmesi Teknikleri: Ampirik Uygulamalar ve Karşılaştırmalı Analiz*. Uzmanlık Yeterlilik Tezi, Ankara: Türkiye Cumhuriyet Merkez Bankası.

- Çelik, M.K. (2010). Bankaların Finansal Başarısızlıklarının Geleneksel ve Yeni Yöntemlerle Öngörüsü. *Yönetim ve Ekonomi: Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 17(2), 129-143.
- DeAngelo, H. ve DeAngelo, L. (2006). The Irrelevance of the MM Dividend Irrelevance Theorem. *Journal of Financial Economics*, 79, 293-316.
- DeAngelo, H., DeAngelo, L. ve Skinner, J. (2004). Are Dividends Disappearing? Dividend Concentration and the Consolidation of Earnings. *Journal of Financial Economics*, 72, 425-456.
- DeAngelo, H., DeAngelo, L. ve Stulz, L. (2006). Dividend Policy and the Earned/Contributed Capital Mix: a Test of the Life-Cycle Theory. *Journal of Financial Economics*, 81, 227-254.
- Dinh, N.Q. ve Afzulpurkar, N.V. (2007). Neuro-Fuzzy MIMO Nonlinear Control For Ceramic Roller Kiln. *Simulation Modelling Practice and Theory*, 15, 1239-1258.
- Fama, E.F. ve Babiak, H. (1968). Dividend Policy: An Empirical Analysis. *Journal of the American Statistical Association*, 63(324), 1132-1161.
- Fama, E. ve French, K. (2001). Disappearing Dividends: Changing From Characteristics Or Lower Propensity To Pay. *Journal of Financial Economics*, 60(1), 3-43.
- Gürel, E. (2008). *Kar Payı Dağıtım Politikalarının Etkinliği ve İMKB Uygulaması*, Yayınlanmamış Doktora Tezi, Ankara: Ankara Üniversitesi Sosyal Bilimler Enstitüsü.
- Funahashi, K.I. (1989). On The Approximate Realization Of Continuous Mappings By Neural Networks. *Neural Networks*, 2(3), 183-192.
- Funahashi, K.I. (1990). On the Approximate Realization of Identity Mappings by 3-Layer Neural Networks. *Transactions of IEICE A*, J73-A, 139-145.
- Hansen, R., Kumar, R. ve Shome, D.K. (1994). Dividend Policy And Corporate Monitoring: Evidence From The Regulated Electric Utility Industry. *Financial Management*, 23(1), 16-22.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. Third Edition, New Jersey: Pearson.
- Hornik, K. (1991). Approximation Capabilities Of Multilayer Feedforward Networks. *Neural Networks*, 4(2), 251-257.

- Hornik, K. (1993). Some New Results On Neural Network Approximation. *Neural Networks*, 6(8), 1069-1072.
- Hornik, K., Stinchcombe, M. ve White, H. (1989). Multilayer Feedforward Networks Are Universal Approximators. *Neural Networks*, 2(5), 359-366.
- Hornik, K., Stinchcombe, M. ve White, H. (1990). Universal Approximation Of An Unknown Mapping And Its Derivatives Using Multilayer Feedforward Networks. *Neural Networks*, 3(5), 551-560.
- Jang J.S.R. (1993). ANFIS: Adaptive-Network-Based Fuzzy İnference System. *IEEE Transactions on Systems, Man and Cybernetics*, 23(3), 665-685.
- Julio, B. ve Ikenberry, D. (2004). Reappearing Dividends. *Journal of Applied Corporate Finance*, 16(4), 89-100.
- Lintner, J. (1956). Distribution of Incomes of Corporations Among Dividends, Retained Earnings, and Taxes. *American Economic Review*, 46, 97-113.
- Kaba, F. (2009). *Kar Payı Dağıtımın Firma Değeri Üzerinde Etkisi ve Bir Uygulama*, Yayınlanmamış Yüksek Lisans Tezi, Sakarya: Sakarya Üniversitesi Sosyal Bilimler Enstitüsü.
- Kaderli, Y. ve Başkaya, H. (2014). Halka Açık Firmalarda Kâr Payı Dağıtım Duyurularının Hisse Senedi Fiyatlarına Etkisinin Ölçülmesi: Borsa İstanbul'da Bir Uygulama. *Adnan Menderes Üniversitesi Sosyal Bilimler Dergisi*, 1(1), 49-64.
- Keskin, Y. (2002). *İşletmelerde Finansal Başarısızlığın Tahmini, Çok Boyutlu Model Önerisi ve Uygulaması*. Yayınlanmamış Doktora Tezi, Ankara: Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü.
- Kim, J., Won, J. ve Jae, K.B. (2010). A Knowledge Integration Model for the Prediction of Corporate Dividends. *Expert Systems with Applications*, 37, 1344-1350.
- Marsh, T.A. ve Merton, R.C. (1987). Dividend Behavior For The Aggregate Stock Market. *Journal of Business*, 60(1), 1-40.
- Miller, M.H.ve Rock, K. (1985). Dividend Policy Under Asymmetric İnformation. *Journal of Finance*, 40(4), 1031-1051.
- Muzir, E. (2013). Impact of Placement Choices and Governance Issues on Credit Risk in Banking: Nonparametric Evidence from an Emerging Market. *Journal of Knowledge Management, Economics and Information Technology*, 3(4), 100-153.

- Nissim, D. ve Ziv, A. (2001). Dividend Changes And Future Profitability. *Journal of Finance*, 56(6), 2111-2133.
- Pendharkar, P.C. (2005). A Threshold-Varying Artificial Neural Network Approach For Classification And Its Application To Bankruptcy Prediction Problem. *Computers and Operations Research*, 32(10), 2561-2582.
- Principe, C.J., Euliano, N.R. ve Lefebvre, W.C. (2000). *Neural And Adaptive Systems: Fundamentals Through Simulations*. London: Wiley.
- Quinlan, J.R. (1993). *C4.5: Programs for Machine Learning*. San Mateo, CA: Morgan
- Rosenblatt, F. (1958). The Perceptron: A Probabilistic Model For Information Storage And Organization In The Brain. *Psychological Review*, 65, 386-408.
- Salehi, M., Kardan, B. ve Aminifard, Z. (2012). Effective Components on the Forecast of Companies' Dividends Using Hybrid Neural Network and Binary Algorithm Model. *Indian Journal of Science and Technology*, 5(9), 3321-3327.
- Schölkopf, B. ve Christopher J.C. (1999). *Advances in Kernel Methods: Support Vector Learning*. MIT Press.
- Shiller, R.J. (1983). Do Stock Prices Move too Much to be Justified by Subsequent Changes in Dividends? Reply. *American Economic Review*, 73(1), 236-37.
- Tatari, M. (1999). *Analysis of Cash vs. Stock Dividend Announcement's Effect on Stock Prices in Istanbul Stock Exchange*, Yayınlanmamış Yüksek Lisans Tezi, İstanbul: Marmara Üniversitesi Sosyal Bilimler Enstitüsü.
- Tsai, C.F. ve Wu, J.W. (2008). Using Neural Network Ensembles For Bankruptcy Prediction And Credit Scoring. *Expert Systems with Applications*, 34(4), 2639-2649.
- Ünlü, U., Bayrayrakdaroğlu, A. ve Ege, İ. (2009). Hisse Senedi Endeks Getirileri ve Temettü Verimi: İmkb 100 ve S&P 500 Endeksleri Üzerine Bir Uygulama. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 11(1), 143-158.
- Vapnik, V.N. (1998). *Statistical Learning Theory*. New York: Wiley.

- Vapnik, V.N., Golowich, S.E. ve Smola, A. (1997). Support Vector Method for Function Approximation, Regression Estimation, and Signal Processing. *Presented at the Advances in Neural Information Processing Systems 9*, MA, MIT Press, Cambridge, 281-287.
- Watts, R. (1973). The Information Content of Dividends. *Journal of Business*, 46(2), 191-211.
- Won, C., Kim, J. ve Jae K.B. (2012). Using Genetic Algorithm Based Knowledge Refinement Model for Dividend Policy Forecasting. *Expert Systems with Applications*, 39, 13472–13479.
- Yakut, E., Elmas, B. ve Yavuz, S. (2014). Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19(2), 139-157.

A Machine Learning Approach for Cash Dividends' Forecasting: A Research on Manufacturing Sector

Extended Abstract

1. Introduction

Dividend payment is one of the factors that affect investment decisions in stock markets. Individual and institutional investors, who expect consistent returns in long run, are seen mostly investing corporate with high and steady stock dividend payment to averse from risk in capital markets. Dividend payment is also considered as an indicator of past and future performance of a corporate. Many studies concerning dividend payment point out that cash dividend payouts are increasing continuously in last decades and becoming as a basic form of a dividend policy. On the other hand dividend is used as one of the main factors to determine the value of corporation regarding the valuation theory. In this context future cash dividends are estimated for assessing of firm's value by discounted cash flow (DCF) method which is widely exploited valuation method.

Despite the correct estimation of cash dividends is of importance for the purpose of valuation and investment decisions, it is difficult to find good theoretical models for forecasting cash dividends successfully. In this regard Marsh and Merton (M&M) (1987) model is seen forecasting dividends more successfully than other models. Consequently, improving a better dividend estimating model than the M&M model can subscribe to not only the advancement of the assessment model for firm valuation but also the investment decisions in stocks markets.

Therefore the purpose of this study is to develop a better model than the M&M model to estimate future dividends in Turkey by applying machine learning techniques, such as Multi-Layer Perception (MLP), Radial Based Function Networks (RBFN), Support Vector Machines (SVM) and Adaptive Neuro-Fuzzy Inference Systems (ANFIS) models.

2. Method

In this study the M&M model's variables, such as stock prices in the previous and past periods and dividend in the previous periods, are applied to forecast next period's dividend without any transformation in machine learning methods. To accomplish the best estimate of next period's cash dividend payout ratios, the estimation performance of the M&M model and five machine learning models, namely One Hidden Layer MLP, Two Hidden Layer MLP, RBFN, SVM and ANFIS are compared with each other. The models are applied with using different softwares such as Microsoft Excel 2010 for the M&M model, NeuroSolutions v5.06 for the ANFIS model and SPSS Clementine 12 for the other models.

All available manufacturing companies listed in the Istanbul Stock Exchange market for the periods from 2003 to 2012 are considered in the study. Data is obtained from the database of FINNET Inc. Totally 420 annual observations from 139 manufacturing firms which have cash dividend records more than at least two years consecutively, are used as a sample. This main sample is split into two subsets, a training set and a validation set. The training subset is used to train the estimation models. The validation subset is used to test the model's forecasting performance with the data which have not been used in developing the estimation models. A training subset and validation subset, consisting of 80% (336/420) and 20% (84/420) of the sample respectively, are randomly selected. The selection of subset composition and measuring the performance of models process is replicated three times (Set 1 to 3). Mean Squared Error (MSE)

method, indicating the approximation between estimates and real values as a percent ratio, is used for measuring the models' performance.

3. Results and Discussion

As a result it is observed that the estimates of the M&M and the RBFN models were sometimes close to real values. But these models showed dividend payout firms as no payout firms or lower payout firms and often produced volatile estimates and even sometimes approached to zero. The SVM model cannot forecast actual dividends because of producing values close to constant. On the other hand, One and Two Hidden Layer MLP models forecasted high paid dividends well, but cannot show same performance concerning low paid dividends. The ANFIS model's performance is occurred significantly different from other models, since not only producing less error than mean MSE value in all iterations, but also having the minimum average MSE value.

The results of study are also tested with three different control variables for robustness. Return of equity ratio, cash and equivalents ratio and total net sales is used as an indicator of profitability, liquidity and size respectively for robustness. In this sense firstly firms in main sample are lined up from low value to high value according to these three control variables. Secondly these three main samples are split into two subsets, a low value set and a high value set. Thirdly every value data set is also split into two subsets randomly in the same way, a training set and a validation set. The selection of subset composition and measuring the performance of models process is also replicated three times (Set 1 to 3). Fourthly the ANFIS model is applied to these validation subsets of every low and high value sets with three replications. Thus the ANFIS model's application is totally realized 18 times in robustness tests. It is occurred that the ANFIS model produced lower average MSE values for subsamples which have not only high correlation between output and inputs but also output with lower variance and narrow range.

4. Conclusion

As a result, the ANFIS model is the most successful model in forecasting dividends among six models namely One and Two Hidden Layer MLP, RBFN and SVM. So the ANFIS method can be used as a model for estimation of future dividends concerning investment decisions in the ISE market and firm valuations by investors.

To generalize the results of this study, the methods must be verified on other developing countries manufacturing sectors. Future research can adopt external variables such as exchange rates or can adopt other machine learning methods such as CHAID, C5.0, CART and QUEST.

